



**UNIVERSIDAD DE CUENCA**

**FACULTAD DE CIENCIAS QUÍMICAS**

**CARRERA DE INGENIERÍA INDUSTRIAL**

**“SELECCIÓN DEL MODELO ESTADÍSTICO ADECUADO PARA  
EL MANEJO DE LA FLUCTUACIÓN DE LA DEMANDA EN  
PYMES”**

TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE INGENIERO  
INDUSTRIAL

**AUTOR:** PEDRO JOSÉ SÁNCHEZ VILLAVICENCIO

010447092-7

**DIRECTOR:** ING. NOÉ RODRIGO GUAMÁN GUACHICHULLCA

010529159-5

OCTUBRE 2017

**CUENCA - ECUADOR**



## **Selección del Modelo Estadístico Adecuado para el Manejo de la Fluctuación de la Demanda en PYMES**

Pedro Sánchez, Rodrigo Guamán

Universidad de Cuenca, Facultad de Ciencias Químicas, Carrera de Ingeniería Industrial  
Cuenca – Ecuador, Fecha de entrega: 13 de octubre de 2017

---

### **Resumen**

Las empresas deben generar pronósticos de la demanda para estimar las ventas de un producto en un periodo futuro, por lo que la modelación estadística es una herramienta esencial para ello. Este ensayo ha tenido como objetivo principal generar un algoritmo que seleccione el modelo estadístico adecuado para el manejo de la fluctuación de la demanda basado en los datos históricos de las pequeñas y medianas empresas (PYMES), para servir como apoyo en la toma de decisiones. Se ha trabajado con métodos estadísticos causales como regresión lineal, exponencial y cuadrática, y con métodos de series de tiempo como promedios móviles y suavización exponencial. Se han usado datos históricos de una empresa comercial de la ciudad de Cuenca para analizarlos mediante los métodos propuestos a través de un paquete de software para ingeniería, cuyo objetivo fue reconocer la técnica estadística que menor error calculado presente, en conjunto con otros parámetros estadísticos que ayudaron a determinar la calidad de los valores analizados. Una vez que se han examinado los datos con todos los modelos se concluyó que el método más adecuado es aquel que demuestre el menor error en sus proyecciones, el cual se verá directamente influenciado por la normalidad y homocedasticidad de la serie de datos.

### **Palabras clave**

Demanda, ventas, pronósticos, series de tiempo, análisis estadísticos, PYMES, algoritmo.



## **Selección del Modelo Estadístico Adecuado para el Manejo de la Fluctuación de la Demanda en PYMES**

Pedro Sánchez, Rodrigo Guamán

Universidad de Cuenca, Facultad de Ciencias Químicas, Carrera de Ingeniería Industrial  
Cuenca – Ecuador, Fecha de entrega: 13 de octubre de 2017

---

### **Abstract**

Enterprises should generate demand forecasts to estimate products sales in a future period, thus, statistical modeling is an indispensable instrument for it. The main objective of this essay is to generate an algorithm, which can select the suitable statistic model to manage demand fluctuation. The algorithm was based on historic data from small and medium enterprises (SMES), to give support in the decision-making process. Causal statistical methods were used such as linear, exponential and quadratic regression, also, time series methods were used regarding moving averages and exponential smoothing. Historic demand data from a commercial enterprise in Cuenca was analyzed with the proposed methods through an engineering statistic software. The purpose was to obtain the statistical technique with the least of errors along with other statistical parameters that helped to determine the analyzed values quality. The adequate model is the one that acquired the least of errors in its projections, which are directly influenced by the statistical normality and homoscedasticity of the data series.

### **Keywords**

Demand, sales, forecasting, time series, statistical analysis, SMES, algorithm.



## Índice

1. Introducción.....	6
1.1. Conceptos generales .....	6
1.2. Determinación del pronóstico de la demanda .....	7
2. Materiales y Métodos .....	8
2.1. Modelos Causales .....	10
2.2. Modelos de Series de Tiempo .....	12
2.3. Medición del error de los pronósticos .....	16
3. Resultados y Discusión .....	18
4. Conclusiones .....	37
Agradecimientos .....	40
Referencias Bibliográficas.....	40



Cláusula de licencia y autorización para publicación en el Repositorio  
Institucional

---

PEDRO JOSÉ SÁNCHEZ VILLAVICENCIO, en calidad de autor y titular de los derechos morales y patrimoniales del trabajo de titulación "SELECCIÓN DEL MODELO ESTADÍSTICO ADECUADO PARA EL MANEJO DE LA FLUCTUACIÓN DE LA DEMANDA EN PYMES", de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, Octubre de 2017

Pedro José Sánchez

PEDRO JOSÉ SÁNCHEZ VILLAVICENCIO

C.I: 0104470927



### Cláusula de Propiedad Intelectual

---

PEDRO JOSÉ SÁNCHEZ VILLAVICENCIO, autora del trabajo de titulación “SELECCIÓN DEL MODELO ESTADÍSTICO ADECUADO PARA EL MANEJO DE LA FLUCTUACIÓN DE LA DEMANDA EN PYMES”, certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, Octubre de 2017

Pedro José Sánchez

PEDRO JOSÉ SÁNCHEZ VILLAVICENCIO

C.I: 0104470927

## 1. Introducción

Debido a su naturaleza productiva o de comercialización, las pequeñas y medianas empresas se verán en la obligación de generar y comparar sistemas de pronóstico para la demanda de todos los productos de su cartera, debido a la variabilidad intrínseca del sistema organizativo. Este pronóstico será la pieza clave para la planificación de los negocios y estrategias, por lo que el sustento estadístico aumentaría la confiabilidad de la toma de decisiones en base a los valores pronosticados.

Para conseguir esta meta se necesita de información histórica relevante que va a ser reproducida por medio de modelos estadísticos, que conforme han avanzado las computadoras y a su fácil acceso y entendimiento se han transformado en las formas más adecuadas y económicas para el desarrollo de pronósticos, tanto en la industria como a nivel académico.

Por consiguiente, un pronóstico posee el objetivo de facilitar las decisiones futuras de la empresa y proveer una valoración del riesgo que involucren las decisiones (Erossa, 2004). De esta forma, la importancia que conlleva un pronóstico depende de la precisión de sus cálculos, los cuales serán afectados por las alteraciones que pueda sufrir en la variabilidad del sistema donde opera la organización (Arrendondo & Vázquez, 2013).

Debido a esto, para disminuir el riesgo en la toma de decisiones gerenciales u

operacionales y lograr prever un comportamiento futuro, así como para suavizar la percepción de incertidumbre, es de suma relevancia hacer uso de toda la información disponible, y no únicamente basarse en supuestos. De hecho, se podría considerar que los modelos de toma de decisiones se ajustan a la realidad de la empresa y no a la del entorno (Arrendondo & Vázquez, 2013). Por lo tanto, es de primordial consideración en la elección de un método de pronóstico que la toma de decisiones de la organización sea facilitada por los resultados obtenidos (Hanke & Wichern, 2010).

### *1.1. Conceptos generales*

Para los autores Pindyck y Rubinfeld (2001) un pronóstico: “es un mecanismo que provee un estimado o conjunto de estimados cuantitativos sobre de la probabilidad de eventos futuros que se generan, fundamentados en la información pasada y actual que sea de interés.”.

Según Hanke y Wichern (2010): “es una predicción de lo que ocurrirá con las ventas actuales de los productos de su empresa. Lo adecuado sería generar un pronóstico con enfoque multifuncional; es decir, considerar las entradas de ventas y mercadeo, finanzas y producción”.

Bajo el criterio de Hanke & Wichern (2010) se recomienda que para la construcción de un pronóstico se deberá seguir un proceso

lógico; este proceso se constituye de los siguientes pasos:

- 1) Formular el problema.
- 2) Reunir los datos.
- 3) Manejar y limpiar los datos.
- 4) Elaborar y valorar el modelo.
- 5) Aplicar el modelo.
- 6) Evaluar el pronóstico.

### 1.2. Determinación del pronóstico de la demanda

Existen dos perspectivas para establecer el pronóstico de la demanda: el enfoque cualitativo y el enfoque cuantitativo. A continuación, hacemos la comparación de los dos enfoques:

Tabla 1. Enfoques para pronósticos de la demanda. (PYME, 2017).

Descripción	Cualitativo	Cuantitativo
Aplicabilidad	Cuando el escenario es impreciso, es decir existen pocos datos.	Cuando la situación es estable y se poseen datos históricos.
Consideraciones	Se basa en la intuición y la experiencia.	Se basa en técnicas matemáticas.
Técnicas	<ul style="list-style-type: none"> <li>• Jurado de opinión ejecutivo compuesto del departamento de ventas.</li> <li>• Método Delphi.</li> <li>• Encuesta del mercado de consumidores.</li> </ul>	<ul style="list-style-type: none"> <li>• Modelos causales.</li> <li>• Modelos de series de tiempo.</li> </ul>

El enfoque cualitativo valora la experiencia y se aprovecha de opiniones para construir pronósticos en forma subjetiva; son usados cuando se carece de información histórica. Por lo contrario, los cuantitativos requieren de información histórica para estimar los valores futuros de la variable de interés. Existen dos técnicas de pronóstico cuantitativos, el modelo causal que se basa en un procedimiento matemático llamado análisis de regresión que relaciona una variable dependiente con una variable independiente a través de una ecuación lineal (Moreno, 2008); y las de series de tiempo que son modelos de proyección histórica que se manejan cuando existen los suficientes registros, pudiendo predecir valores futuros de la variable de interés, suponiendo que el patrón histórico de los datos continuará (Masini & Vazquez, 2014).

Según Hanke y Wichern (2010) para generar pronósticos se consideran suficientes por lo menos 20 datos de periodos anteriores hasta la fecha.

Por lo tanto, luego de la revisión bibliográfica correspondiente, se determinó que, se tomará en cuenta el enfoque cuantitativo basado en el modelo causal y en el modelo de series de tiempo debido a su fácil acceso y uso, dado que se ajustan a las



necesidades de las pequeñas y medianas empresas.

### Hipótesis

Se puede establecer, a través de un algoritmo, el mejor modelo predictor que se ajuste a una situación específica.

$$n * \begin{cases} H_o: & \text{Modelo } i \text{ se ajusta a los datos} \\ H_a: & \text{Modelo } i \text{ no se ajusta a los datos} \end{cases}$$

- Ho = hipótesis
- Ha = hipótesis alternativa
- n = número de modelos estudiados
- i = cada modelo estudiado

### Objetivo General

Generar un algoritmo que seleccione el método estadístico que mejor se adapte a una determinada empresa basado en los datos históricos que esta disponga.

### Objetivos Específicos

- Determinar un modelo para la predicción de la demanda.
- Comparar varianzas obtenidas mediante el moldeado de datos con diferentes métodos y probar la validez del modelo.
- Interpretar cuando los errores son demasiado grandes entre métodos.
- Determinar un algoritmo de elección para una empresa determinada.

## 2. Materiales y Métodos

La situación específica a la que se hace referencia en la hipótesis, para este estudio en particular, es la predicción de la demanda para las PYMES.

Se determinó que la población meta serán las pequeñas y medianas empresas productoras y comercializadoras de la ciudad de Cuenca (este estudio también puede ser aplicado a nivel nacional en empresas de igual naturaleza); categorizando el sector comercial como muestra, debido a la variabilidad que este sector puede presentar en sus demandas.

El estudio se lo desarrollará con datos reales de la demanda de una empresa categorizada como PYME, analizando las unidades de producto demandado de una empresa piloto comercializadora de Cuenca, para la aplicación de la metodología aquí propuesta.

Para seleccionar a la empresa cuya información será empleada el requisito fue la existencia de suficientes registros históricos reales de su demanda, que según bibliografía anteriormente mencionada son mínimo 20 datos de periodos anteriores hasta la fecha, para poder ejecutar un análisis estadístico apropiado. Luego del proceso de selección, la recopilación de datos se obtuvo de una empresa comercializadora de la ciudad de Cuenca, que accedió a facilitar datos de las demandas de 4 productos (Tabla 2) en períodos mensuales desde el año 2014,

guardando confidencialidad con el nombre y productos de la empresa. A estos productos se

Año	Periodo	a	b	d	k
2014	ene	48	103	127	33
2014	feb	42	84	95	27
2014	mar	23	76	91	24
2014	abr	25	70	75	25
2014	may	21	75	155	20
2014	jun	55	134	142	38
2014	jul	21	56	77	36
2014	ago	38	53	90	16
2014	sep	46	112	122	34
2014	oct	25	95	94	22
2014	nov	30	55	66	37
2014	dic	43	112	224	39
2015	ene	26	38	54	23
2015	feb	19	51	57	25
2015	mar	36	42	61	17
2015	abr	81	47	54	14
2015	may	119	81	93	11
2015	jun	102	29	58	18
2015	jul	122	48	49	14
2015	ago	120	47	60	18
2015	sep	129	42	62	10
2015	oct	70	2229	1533	18
2015	nov	88	39	59	15
2015	dic	117	169	223	22
2016	ene	107	46	58	10
2016	feb	84	22	44	6
2016	mar	67	51	59	7
2016	abr	114	126	112	34
2016	may	1314	55	85	17
2016	jun	162	117	108	39
2016	jul	151	29	54	12
2016	ago	114	33	51	12
2016	sep	238	24	41	8
2016	oct	181	43	47	39
2016	nov	143	8920,28	81	22
2016	dic	101	223	128	8
2017	ene	118	65	43	3
2017	feb	15	-55,54	51	7
2017	mar	14	61	49	25
2017	abr	13	62	84	33
2017	may	12	84	107	9
2017	jun	15	62	47	24
2017	jul	35	72	82	17
2017	ago	14	110	109	10

Tabla 2. Registro histórico de la demanda de 4 productos de una empresa comercializadora de la ciudad de Cuenca. (Elaboración propia).

los caracteriza como no perecibles, de compra frecuente y venta directa.

Los programas que se utilizarán para este ensayo académico serán Excel® 2016 para gráficas y Minitab® 18 para el modelamiento estadístico. Se prefirió Minitab® 18 por los parámetros que entregan sus pruebas estadísticas, pero se pueden utilizar otros softwares estadísticos para realizar el análisis, debido a que la propuesta de este ensayo académico es desarrollar un algoritmo que pueda funcionar utilizando cualquier programa estadístico o en su caso que pueda ser programado.

Las variables que se manejarán en el estudio son el tiempo y la cantidad de productos demandados. El tiempo dictamina, de manera lineal, cuál ha sido la cantidad o fluctuación de la demanda, reflejando posibles variaciones que señalen estacionalidades u otro tipo de comportamientos. La cantidad de productos demandados muestra la necesidad de los consumidores respecto a cierto producto.

Dentro del enfoque cuantitativo se utilizarán los siguientes modelos estadísticos, los cuales estarán presentes en el análisis de todos los datos, pero divididos en dos niveles debido a la complejidad de su desarrollo:

#### Nivel 1: Métodos Causales

- Regresión lineal.
- Regresión exponencial.
- Regresión cuadrática.

## Nivel 2: Métodos de Series de Tiempo

- Regresión de promedios móviles.
  - Promedio móvil de 1 periodo.
  - Promedio móvil de 2 periodos.
  - Promedio móvil de 3 periodos.
- Suavizamiento exponencial.
  - Con alfa igual a 0,2.
  - Con alfa igual a 0,5.
  - Con alfa igual a 0,8.

Método	Patrón de datos	Horizonte de tiempo	Tipo del modelo	Datos mínimos requeridos	
				No estacionales	Estacionales
Simple	ST,T,S	S	TS	1	
Promedios simples	ST	S	TS	30	
Promedios móviles	ST	S	TS	4-20	
Suavizamiento exponencial	ST	S	TS	2	
Suavizamiento exponencial lineal	T	S	TS	3	
Suavizamiento exponencial cuadrático	T	S	TS	4	
Suavizamiento exponencial estacional	S	S	TS		2 x s
Filtración adaptativa	S	S	TS		
Regresión simple	T	I	C	10	
Regresión múltiple	C,S	I	C	10 x V	
Descomposición clásica	S	S	TS		5 x s
Modelos de tendencia exponencial	T	I,L	TS	10	
Ajuste de la curva S	T	I,L	TS	10	
Modelos de Gompertz	T	I,L	TS	10	
Curvas de crecimiento	T	I,L	TS	10	
Census X-12	S	S	TS		6 x s
Box-Jenkins	ST,T,C,S	S	TS	24	3 x s
Indicadores principales	C	S	C	24	
Modelos econométricos	C	S	C	30	
Regresión múltiple de series de tiempo	T,S	I,L	C		6 x s

Patrón de datos: ST, estacionario; T, de tendencia; S, estacional; C, cíclico  
 Horizonte de tiempo: S, corto plazo (menos de tres meses); I, mediano plazo; L, largo plazo  
 Tipo de modelo: TS, serie de tiempo; C, causal  
 Estacional: S, longitud de la estacionalidad  
 Variable: V, número de variables

Figura 1. Técnicas de pronósticos. (Hanke & Wichern, 2010).

En la figura 1 podemos observar los diferentes métodos estadísticos de pronóstico, dentro de las cuales se encuentran los propuestos en esta investigación.

Cabe recalcar que el algoritmo que se plantea desarrollar en este estudio se conseguirá mediante la modelación de todos los datos de los cuatro productos, con todas las técnicas estadísticas señaladas anteriormente, para así obtener como resultado un algoritmo

que se haya adaptado a la situación específica de esta empresa comercial.

- **Algoritmo:** Conjunto de operaciones secuenciales que constituyen un modelo que al ejecutarse paso a paso se obtendrá una solución a un problema (Balderrama, 2011).

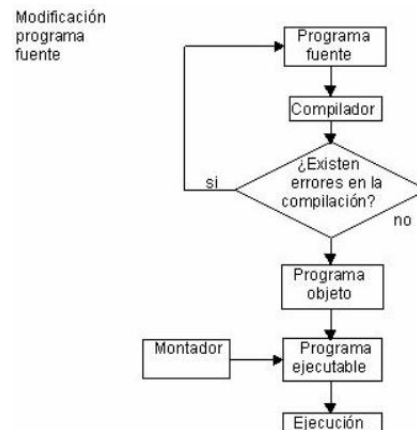


Figura 2. Algoritmo para las fases de la ejecución de un programa. (Avalos, 2010)

## 2.1. Modelos Causales

Conocidos también como modelos asociativos; estos asumen que el elemento a pronosticar muestra una relación causa-efecto con una o más variables independientes. Su propósito es representar la forma de relación entre las variables y usarla para predecir valores futuros de la variable dependiente. Dentro de los métodos causales mayormente utilizados se encuentran las técnicas de regresión (Contreras, Atziry, Martinez, & Sánchez, 2016).

En la figura 2 se visualizan las proyecciones que se generan cuando se modelan regresiones (Esparza, 2008).

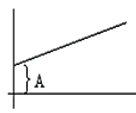

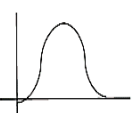
TIPOS DE PROYECCIÓN	ECUACIÓN F (TIEMPO)	GRAFICO
Proyección lineal	$Y = A + Bx$	
Proyección Exponencial	$Y = ae^{bx}$	
Proyección Cuadrática	$Y = a + bx + cx^2$	

Figura 3. Proyecciones. (Esparza, 2008).

A continuación, se detallan los métodos causales utilizados en este estudio.

- **Regresión Lineal:** El objetivo de este método es la comprensión de la naturaleza probabilística del modelo de regresión de forma que, a partir de un valor observado de  $x$  (variable independiente), se ha logrado observar varios valores posibles de  $y$  (variable dependiente) (Moreno, 2008).

Es decir:

$$y = a_0 + a_1x + \varepsilon$$

Donde:

- $y$  = es la variable dependiente que se pretende estimar; en este caso, la demanda.
- $a_0$  = parámetro de regresión correspondiente al valor estimado de la demanda en el periodo cero.
- $a_1$  = parámetro de regresión correspondiente al crecimiento o disminución (depende del signo) del valor.
- $x$  = variable independiente.
- $\varepsilon$  = componente de error aleatorio.

Los estadísticos han desarrollado ecuaciones que se utilizan para encontrar los valores de  $a$  y  $b$  para cualquier regresión lineal. (Heizer & Render, 2009).

La pendiente  $b$  se encuentra mediante:

$$b = (\sum xy - \bar{x}\bar{y}) / (\sum x^2 - n\bar{x}^2)$$

Y la intersección con el eje  $y$ ,  $a$ , se calcula:

$$a = \bar{y} - b\bar{x}$$

Donde:

- $\sum$  = signo de sumatoria.
- $x$  = valores conocidos de la variable independiente.
- $y$  = valores conocidos de la variable dependiente.
- $\bar{x}$  = promedio de los valores de  $x$ .
- $\bar{y}$  = promedio de los valores de  $y$ .
- $n$  = número de puntos de datos u observaciones.

- **Regresión exponencial:** Se utiliza para conocer la relación de dos variables entre las cuales se supone que poseen una relación exponencial; por ejemplo, el crecimiento poblacional en el tiempo (Quijada & Banda, 2011).

Es decir:

$$y = a_0e^{a_1x} + \varepsilon$$

Donde:

- $y$  = es la variable dependiente por estimar o valor futuro.
- $a_0$  = parámetro de regresión o valor inicial o valor presente.

- $e$  = número de Euler o constante de Napier.
  - $a_1$  = parámetro de regresión o tasa de crecimiento o decrecimiento.
  - $x$  = variable independiente.
  - $\varepsilon$  = término de error.
- **Regresión cuadrática o parabólica:** Se emplea cuando aquellos fenómenos que se observan en un diagrama de dispersión se muestran con una concentración de puntos inicial ascendentes e inmediatamente descendentes o lo contrario (Martínez, 2012)

Es decir:

$$y = a_0 + a_1x + a_2x^2 + \varepsilon$$

Donde:

- $y$  = es la variable dependiente que se pretende estimar; en este caso, la demanda.
- $a_0$  = parámetro de regresión o valor inicial o valor presente.
- $a_1, a_2$  = parámetros de regresión o tasas de crecimiento o decrecimiento.
- $x$  = valores conocidos de la variable independiente.
- $\varepsilon$  = término de error.

## 2.2. Modelos de Series de Tiempo

Las series de tiempo dependen únicamente de la historia de la demanda del producto que se está pronosticando. Se manejan capturando los estándares de los datos históricos,

extrapolándolos en el futuro. Estos modelos se aplican cuando se asume una cantidad razonable de datos y una continuidad en el futuro próximo de las circunstancias que se presentaron en el pasado (Beltrán, 2013).

Las series de tiempo poseen variaciones que se clasifican en sistemáticas y aleatorias; las sistemáticas suceden con regularidad y se pueden modelar; las aleatorias son producidas por condiciones aisladas como terremotos, huelgas y, como consecuencia, son difíciles de modelar (Moreno, 2008).

Dentro de las variaciones sistemáticas existen tres tipos de componentes: tendencia secular, variaciones cíclicas o constantes y variaciones estacionales (Moreno, 2008).

Tendencia secular: La tendencia de una serie de tiempo caracteriza el patrón gradual y consistente de las variaciones de la propia serie, que suponen ser la consecuencia de fuerzas constantes afectando directamente el crecimiento o la disminución de la misma (Calderón & García, 2006).




Figura 4. Tendencia secular. (Webster, 2011).

Este gráfico ejemplifica la tendencia secular, aunque los datos muestran una variación considerable por encima y por abajo de la recta de tendencia, esta es claramente ascendente (Webster, 2011).

Variación estacional: El componente estacional de una serie de tiempo constituye la variabilidad en los datos debido a influencias de las estaciones. Es decir, las fluctuaciones de las series que recurren año tras año en los mismos meses (o en los mismos trimestres) del año, más o menos con la misma intensidad, corresponden a estas variaciones (Calderón & García, 2006).




Figura 5. Variación estacional. (Webster, 2011).

Esta gráfica muestra patrones que se repiten regularmente durante un periodo anual (Webster, 2011).

Variación Cíclica: Conocida también como constante. Este componente presenta movimientos a mediano plazo, periodos superiores al año que se renuevan de forma casi periódica por lo que tienen un marcado carácter económico (Beltrán, 2013).




Figura 6. Variaciones cíclicas. (Webster, 2011).

Se muestra un ejemplo de variaciones cíclicas, las cuales presentan 4 fases: 1) Alza o expansión, durante el cual la actividad comercial se acelera; 2) pico, cuando la actividad económica tiene su punto más alto; 3) el descenso, cuando la actividad económica se merma; y 4) la depresión, cuando la actividad está en su punto mínimo (Webster, 2011).

Una vez analizados los componentes de las series de tiempo se localizaron métodos estadísticos con los cuales se realizan pronósticos. A continuación, se describen los métodos de series de tiempo utilizados en este estudio:

- **Promedio móvil:** Se detalla como una serie de promedios aritméticos y se usará siempre y cuando no exista una tendencia definida en los datos a manejar, es decir, que se conserven estables (PYME, 2017).






Figura 7. Promedio móvil. (Bolaños , 2013).

- **Promedio móvil simple:** Se usa para eliminar las alteraciones de las fluctuaciones que se producen arbitrariamente y valorar el promedio de una serie de tiempo. Calcula la demanda promedio para los  $n$  periodos recientes con la finalidad de manejarla como pronóstico del periodo siguiente. Al conocer la demanda, el dato más antiguo incluido en el promedio anterior se reemplaza por la demanda actualizada y finalmente se calcula el promedio nuevamente (Sierra, 2013).

Es decir:

$$F_{t+1} = (D_t + D_{t-1} + D_{t-2} + \dots + D_{t-(n+1)}) / n$$

Donde:

- $F_{t+1}$  = pronóstico para el periodo  $t+1$ .
- $D_t$  = demanda real en el periodo  $t$ .
- $n$  = número total de periodos incluidos en el promedio. Generalmente se usan 1, 2 y 3 periodos.

- **Promedio móvil doble:** Se usa para pronosticar datos de series de tiempo que poseen tendencia lineal. Este método

calcula promedios móviles en conjunto y se deduce un segundo conjunto como un promedio móvil del primer conjunto. La construcción de un promedio móvil doble se resume en las siguientes cinco ecuaciones (Hanke & Wichern, 2010).

El primer paso por realizar es usar la ecuación (1) para calcular el promedio móvil de orden  $n$ :

$$(1) M_t = (D_t + D_{t-1} + D_{t-2} + \dots + D_{t-(n+1)}) / n$$

Donde:

- $D_t$  = demanda real en el periodo  $t$ .
- $n$  = número de periodos en el promedio móvil.

Segundo se usa la ecuación (2) para calcular el segundo promedio móvil:

$$(2) M_t' = (M_t + M_{t-1} + M_{t-2} + \dots + M_{t-(n+1)}) / n$$

Se emplea la ecuación (3) para desarrollar un pronóstico, sumando al promedio móvil simple la diferencia entre el promedio móvil simple y el segundo promedio móvil.

$$(3) a_t = M_t + (M_t - M_t') = 2M_t - M_t'$$

La ecuación (4) es un ajuste añadido, que es similar a la medida de cambio a lo largo de la serie:

$$(4) b_t = [2/(n-1)] [M_t - M_t']$$

Finalmente, se usa la ecuación (5) para realizar el pronóstico de  $p$  periodos en el futuro.

$$(5) F_{t+p} = a_t + b_t p$$

Donde:

➤  $p$  = número de periodos futuros por pronosticar.

- **Promedio móvil ponderado** Al momento que se muestra una tendencia es posible manejar ponderaciones, y dar mayor realce a los valores recientes. De esta forma las técnicas de pronóstico responden de manera rápida a los cambios, dado que pueden dar mayor peso a los periodos más actuales. La selección de las ponderaciones es arbitraria dado que no hay una formula preestablecida. Por esta razón, decidir qué ponderaciones usar requiere de experticia. (Heizer & Render, 2009).

Es decir:

$$F_{t+1} = (W_1 D_t + W_2 D_{t-1} + W_3 D_{t-2} + \dots + W_n D_{t-(n+1)}) / \sum W_n$$

Donde:

- $F_{t+1}$  = pronóstico para el periodo  $t+1$ .
- $W$  = ponderación dada.
- $D_t$  = demanda real en el periodo  $t$ .
- $n$  = número total de periodos incluidos en el promedio.

A pesar de que pueden ser prácticos para suavizar las fluctuaciones inesperadas en el patrón de la demanda, se pueden presentar tres problemas al utilizar el

promedio móvil simple y el ponderado (Heizer & Render, 2009).

1. Incrementar el tamaño de  $n$  suaviza adecuadamente las fluctuaciones, pero resta perceptibilidad al método frente a cambios reales en los datos.
  2. Los promedios móviles no revelan apropiadamente las tendencias debido a que al ser promedios retardan los valores reales.
  3. Se requieren de una cantidad considerable de datos históricos para su cálculo.
- **Suavizamiento exponencial:** Es una técnica de promedio móvil ponderado muy minuciosa que calcula el promedio de una serie de tiempo. Este método se usa con mayor frecuencia debido a su simpleza y la pequeña cantidad de valores que necesita. En contraste con la técnica de promedio móvil ponderado, que necesita  $n$  periodos de demanda pasada y  $n$  ponderaciones, esta usa únicamente tres tipos de datos: el pronóstico del último periodo, la demanda de dicho periodo y un parámetro suavizador, alfa ( $\alpha$ ), cuyo valor fluctúa entre 0 y 1. Para realizar un pronóstico con suavización exponencial, se requiere calcular un promedio ponderado de la demanda más reciente y el pronóstico calculado para el último periodo (Sierra, 2013).



Es decir:

$$F_{t+1} = \alpha D_t + (1 - \alpha)F_t = F_t + \alpha(D_t - F_t)$$

Donde:

- $F_{t+1}$  = pronóstico para el periodo  $t+1$ .
- $F_t$  = pronóstico del periodo  $t$ .
- $D_t$  = demanda real en el periodo  $t$ .
- $\alpha$  = ponderación o constante de suavizamiento; un  $\alpha$  cercano a uno da una alta velocidad de respuesta, mientras que un  $\alpha$  cercano a cero da una baja velocidad de respuesta.

La constante  $\alpha$ , se presenta usualmente entre un intervalo de 0,05 a 0,50 para estudios de negocios. Esta puede tomar valores altos como 0,8 cuando se da mayor peso a los valores más actuales y/o cuando el promedio subyacente tiene probabilidades de cambiar, sin embargo,  $\alpha$  es baja como 0,2 cuando se da más peso a datos anteriores y/o cuando el promedio en que se basa es bastante estable. Por ejemplo, cuando  $\alpha = 0,5$ , el nuevo pronóstico se basa casi por completo en la demanda de los últimos tres o cuatro periodos. Cuando  $\alpha = 0,1$ , el pronóstico pone poco peso en la demanda reciente y toma en cuenta los valores históricos de muchos periodos atrás (hasta casi 19) (Heizer & Render, 2009).

### 2.3. Medición del error de los pronósticos

Existe una variedad de técnicas cuyo objetivo es sintetizar los errores ocasionados por los modelos de pronósticos; gran parte de estas

técnicas son el promedio de alguna función de la diferencia entre los valores reales con los valores pronosticados. Este análisis se conoce como residuales (Hanke & Wichern, 2010).

Es decir:

$$\begin{aligned}\varepsilon &= \text{Demanda real} - \text{Valor pronosticado} \\ &= A_t - F_t\end{aligned}$$

Donde:

- $\varepsilon$  = error residual.
- $A_t$  = demanda real en el periodo  $t$ .
- $F_t$  = pronóstico del periodo  $t$ .

A continuación, se explican los errores presentes en esta investigación.

- **Error porcentual absoluto medio (EPMA o MAPE por sus siglas en inglés):** Este método obtiene el error por medio de porcentajes. Se calcula al conseguir el error absoluto de cada periodo, este se divide entre el valor real observado en ese período y luego se promedian estos errores porcentuales absolutos. Finalmente, el resultado se multiplica por 100 para expresarlo como porcentaje (Hanke & Wichern, 2010).

Es decir:

$$MAPE = (100/n) * \sum[(A_t - F_t) / A_t]$$

Donde:

- $\sum$  = signo de sumatoria.
- $A_t$  = dato real.
- $F_t$  = dato pronosticado.
- $n$  = cantidad de períodos considerados.

- **Desviación media absoluta (DMA o MAD por sus siglas en inglés):** Este método evalúa la exactitud del pronóstico realizado. Se obtiene promediando todos los errores de la proyección, independientemente de que sean positivos o negativos (Corres, Passoni, Zárate, & Esteban, 2014).

Es decir:

$$MAD = \sum[(A_t - F_t) / n]$$

Donde:

- $\sum$  = signo de sumatoria.
- $A_t$  = dato real.
- $F_t$  = dato pronosticado.
- $n$  = cantidad de períodos considerados.

- **Error cuadrático medio (ECM o MSD/MSE por sus siglas en inglés):** Es una medida de error absoluto en la cual se ajusta la diferencia entre los datos históricos y los datos pronosticados para evitar que los errores positivos y negativos se cancelen entre sí. En otras palabras, cada error se elevará al cuadrado; para posteriormente sumarlos y finalmente dividirlos entre el número de observaciones (Montero, 2011). Es decir:

$$MSD = \sum[(A_t - F_t)^2 / n]$$

Donde:

- $\sum$  = signo de sumatoria.
- $A_t$  = dato real.
- $F_t$  = dato pronosticado.
- $n$  = cantidad de períodos considerados.

En el caso de que los productos presenten datos fuera de su rango o tendencia se utilizará el método de los cuartiles para determinar si son valores anormales o erráticos.

Cuartiles: Son medidas estadísticas de posición que poseen la propiedad de dividir una serie estadística en cuatro grupos de números con igual cantidad de términos. Gracias a esto se puede evaluar rápidamente la dispersión y la tendencia del conjunto de datos mediante una gráfica de caja, señalando valores atípicos<sup>1</sup> en el caso que se presenten (Sánchez, 2009).

Es decir:

$$Q_k = k(n/4)$$

Donde:

- $Q$  = cuartil.
- $k$  = número del cuartil que se desea obtener (1 al 4).
- $n$  = total de datos de la distribución.

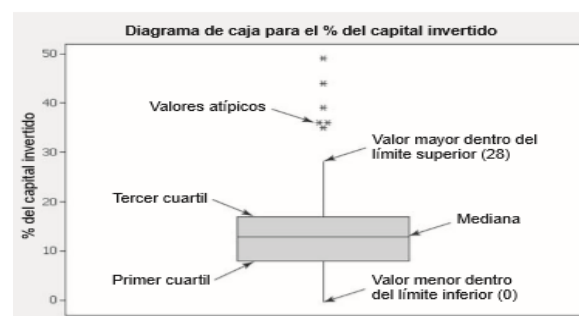


Figura 8. Gráfica de Caja. (Hanke & Wichern, 2010).

<sup>1</sup> Atípicos: Que no encaja en un tipo o modelo.

Esta figura representa la gráfica de caja del ingreso neto como un porcentaje del capital invertido para una muestra de 209 compañías en una encuesta de Fortune 500 (Hanke & Wichern, 2010).

En consecuencia, para la medición del error de los pronósticos se seleccionó la técnica del error porcentual absoluto medio (EPMA o MAPE por sus siglas en inglés) debido a su objetividad y solidez al momento de calcular el menor error de todos los modelos estadísticos. En adición, cuando se observen datos extraños con mucha variabilidad se utilizará, en Minitab®, la gráfica de cajas (cuartiles), para analizar las series de datos y observar si efectivamente existen valores atípicos o disruptores<sup>2</sup> que puedan alterar el estudio.

Finalmente, para tener un modelo de pronóstico con una mayor robustez este debe superar las pruebas estadísticas propuestas por el software Minitab® las cuales ayudarán a determinar si un método es mejor que otro, ya que, en ciertos casos, tienen mayor importancia que el error. Las principales pruebas estadísticas son las siguientes:

Hipótesis de la normalidad: Esta afirma que los residuos del modelo mantienen una distribución normal. Esta hipótesis se contrasta

---

<sup>2</sup> Disruptivo: Es lo que produce una ruptura brusca o interrupción súbita.

a partir de los residuos estandarizados  $i = 1^n$  (Vilar, 2006).

Minitab® utiliza la prueba de Anderson Darling y Kolmogorov, buscando un “valor p”. Para que exista normalidad, gráficamente los puntos deben seguir la línea de distribución normal y el resultado del “valor p” tienen que ser mayor a 0,05. Para este estudio se considera un “valor p” mayor a 0,1 como medida más fuerte de robustez estadística.

Homocedasticidad o prueba de varianzas iguales: Se define como la igualdad de varianzas en distintas poblaciones. Este supuesto es muy importante en modelos de regresión lineal y análisis de varianza debido a que describe la situación en la cual el término de error es el mismo en todos los valores de las variables independientes y admite hacer inferencias sobre parámetros del modelo (Alzate, Aldana, & Hernández, 2016).

En este estudio realizado con Minitab®, la homocedasticidad se comprueba únicamente de manera gráfica cuando los puntos están distribuidos de la forma más desordenada posible dentro del área de la gráfica.

### 3. Resultados y Discusión

Con el fin de seleccionar el método estadístico más adecuado para manejar la fluctuación de la demanda, se moldearon datos de 4 productos; cada uno de ellos con 44 valores históricos de demanda real pertenecientes a



una empresa comercial de la ciudad de Cuenca.

Mediante el programa Excel<sup>®</sup> se procedió a graficar en series tiempo los 4 productos con sus correspondientes valores junto a sus ecuaciones para apreciar la disposición de los datos crudos a través del tiempo, ubicando posibles estacionalidades, ciclicidades y tendencias para que puedan ser corroboradas.

En Minitab<sup>®</sup> se inició el estudio al nivel uno, el cual incluía el modelado de regresión lineal, posteriormente regresión exponencial para terminar con regresión cuadrática. El nivel dos se inició con el modelo de promedio móvil simple de un periodo, segundo con el promedio móvil simple de dos periodos y tercero con el promedio móvil simple de tres periodos, los cuales se tomaron según recomendaciones bibliográficas; y para finalizar el nivel dos, se utilizó el método de suavizamiento exponencial con alfas de 0,2, 0,5 y 0,8 en ese orden, basados en la bibliografía (págs. 12 y 13). Tanto el promedio móvil doble como el ponderado fueron exentos del estudio en Minitab<sup>®</sup> debido a que el programa no permitía su estudio, pero se recomienda implementarlos con otros programas para su estudio en PYMES.

Siguiendo las recomendaciones bibliográficas y la sugerencia de expertos en estadística, todos los métodos de todos los niveles pronosticaron un periodo hacia adelante, ya que es el único con el que se puede tener un 95% de confianza. A partir del

segundo periodo la confianza decae a un 30% convirtiendo los datos que se calculen a futuro en predicciones más no en pronósticos.

Con los datos totalmente modelados en Minitab<sup>®</sup> se podía apreciar mediante múltiples gráficas y observaciones si existía variabilidad o no, pudiendo dirimir a primera vista si se presentarían inconvenientes en el modelado.

Con los resultados de todos los métodos de los dos niveles se realizó el análisis del menor error (MAPE) y la mayor normalidad (valor p) de cada uno de ellos gracias a que Minitab<sup>®</sup> automáticamente calculó estos parámetros.

En el caso de que se presenten productos con datos atípicos o disruptivos, dichos productos serán analizados con y sin los mencionados datos para una comparación y examinación más detallada sobre su variabilidad y para determinar cuál es la mejor situación y método para esos productos.

El procedimiento anteriormente detallado se lo realizó a los cuatro productos comenzando por el “a” hasta terminar con el “k”. Los tres primeros presentaban picos (datos atípicos o disruptivos) por lo que necesitaban un análisis más profundo con las técnicas propuestas, ayudando en la comparación de los métodos utilizados y dando una mejor perspectiva para la selección del modelo que mejor se ajuste a ellos. El último producto mantuvo un comportamiento normal en el tiempo y sirvió para la

demonstración del modelo propuesto en casos sin anomalías.

Para fines ilustrativos se recopiló la información de los resultados de todos los métodos y sus variaciones en tablas de cada producto para facilitar el proceso de selección de los mejores modelos.

### Producto “a”

El producto *a* fue el primero en ser tratado, exhibiendo desde un comienzo un comportamiento normal acorde a sus valores, hasta llegar al periodo 29, correspondiente a mayo del 2016, con un pico de 1314 unidades, el cual se encontraba extremadamente fuera de rango de la tendencia que exhibían los datos.




Gráfico 1. Demanda Real Unificada producto “a”. (Elaboración propia).




Gráfico 2. Demanda Real Anual producto "a". (Elaboración propia).

Primero se examinó la información mediante la gráfica de caja (cuartiles), la cual confirmó de forma definitiva que el periodo 29 es un valor atípico o disruptivo; por lo tanto, se realizó el estudio con y sin este dato.

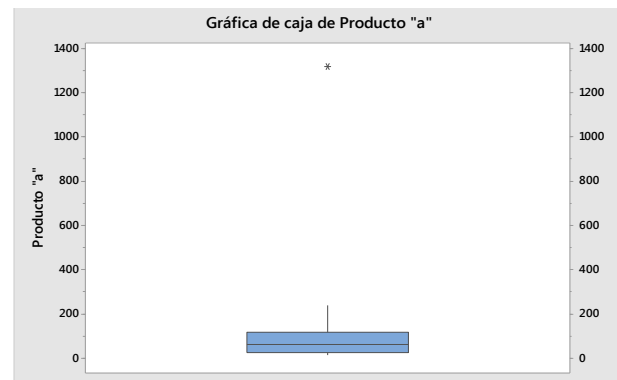


Gráfico 3. Gráfica de caja, producto "a". (Elaboración propia).

Tabla 3. Resultados del Producto "a" en Minitab®. (Elaboración propia).

Producto	Intervalo de Confianza Superior	Pronóstico	Intervalo de Confianza Inferior	N	Valor p	Longitud Estacional	Método Estadístico	Periodo	MAPE	Ecuación	CAUSALES
a		150,6		44	<0,005	-	T. L.	1	192,4	$Y_t = 52,0 + 2,19 \times t$	
		68,06		44	<0,005	-	T. E.	1	102,9	$Y_t = 47,572 \times (1,0080^t)$	
		22,94		44	<0,005	-	T. C.	1	145,2	$Y_t = -75,6 + 18,84 \times t - 0,370 \times t^2$	

a sin Valores Atípicos o Disruptivos	124,84	44	<0,005	17	D. E.	1	160,8	$Y_t = 49,4 + 2,77 \times t$	SERIES DE TIEMPO
	719,47	44	<0,005	16	D. E.	1	188,6	$Y_t = 43,7 + 3,00 \times t$	
	80,51	44	<0,005	15	D. E.	1	259,8	$Y_t = 74,1 + 1,16 \times t$	
	132,9	44	<0,005	14	D. E.	1	214,3	$Y_t = 26,8 + 2,82 \times t$	
	515,8	14	-487,8	43	<0,005	1	69,7	-	SERIES DE TIEMPO
	472,8	24,5	-423,8	42	<0,005	2	75,7	-	
	453,8	21,33	-411,13	41	<0,005	3	86,4	-	
	264,99	86,09	-92,8	44	<0,005	-	S. E. Ó. $\alpha=0,057$	162,9	-
	232,89	51,02	-130,86	44	<0,005	-	S. E. $\alpha=0,2$	137,5	-
	199,56	20,11	-159,34	44	<0,005	-	S. E. $\alpha=0,5$	81,7	-
	202,26	17,38	-167,5	44	<0,005	-	S. E. $\alpha=0,8$	70,1	-
	97,18	43	0,518	-	T. L.	1	132,96	$Y_t = 49,0 + 1,094 \times t$	CAUSALES
	59,6	43	0,011	-	T. E.	1	95,08	$Y_t = 46,940 \times (1,0054^t)$	
	23,57	43	0,229	-	T. C.	1	93,17	$Y_t = -24,6 + 10,91 \times t - 0,2231 \times t^2$	
	87,81	43	0,348	16	D. E.	1	118,66	$Y_t = 40,6 + 1,486 \times t$	
	99,53	43	0,481	15	D. E.	1	114,91	$Y_t = 35,6 + 1,686 \times t$	SERIES DE TIEMPO
	100,03	43	0,486	14	D. E.	1	116,72	$Y_t = 36,4 + 1,677 \times t$	
	84,11	14	-56,11	42	0,099	1	56,97	-	
	97,16	24,5	-48,16	41	0,075	2	58,74	-	
	97,98	21,33	-55,32	40	0,162	3	67,79	-	
	76,06	17,76	-40,56	43	0,035	-	S. E. Ó. $\alpha=0,765963$	53,86	-
	123,21	42,43	-38,35	43	0,176	-	S. E. $\alpha=0,2$	103,81	-
	83,54	20,09	-43,36	43	0,057	-	S. E. $\alpha=0,5$	66,35	-
	76,21	17,38	-41,45	43	0,054	-	S. E. $\alpha=0,8$	53,61	-

\*T.L. = Tendencia Lineal; T.E. = Tendencia Exponencial; T.C. = Tendencia Cuadrática; D.E. = Descomposición Estacional; P.M. = Promedio Móvil; S.E.O. = Suavizamiento Exponencial Óptima calculada por Minitab®; S.E. = Suavizamiento Exponencial.

Observando la tabla 3 se presentan los resultados del producto  $a$ . Se pueden apreciar las diferentes variaciones de información de acuerdo con los diferentes métodos utilizados. Resalta el hecho que dentro de los modelos causales solo sus métodos tienen ecuaciones debido a que se tratan de regresiones. Las diferentes longitudes estacionales de la descomposición estacional se deben a que, gracias a la disposición de los datos y a su correspondiente gráfica, se detectó estacionalidad en la serie de valores

determinando que esta se encontraba entre los 17, 16, 15 o 14 periodos; en consecuencia, se realizaron pruebas con los mencionados periodos para encontrar el más apropiado. También se observan intervalos de confianza, que aparecen solo en los métodos de series de tiempo, los cuales arrojan un rango para el pronóstico, pero que no serán de interés en este estudio.

Finalmente se pueden destacar cuales son los mejores métodos estadísticos para el

producto *a* para ambos casos, basados en el menor error y la mayor normalidad.

### Análisis del producto "a" con dato atípico

Para el caso con el dato atípico se observa que la mejor técnica de regresión es la tendencia exponencial, mientras que en series de tiempo la técnica apropiada es el promedio móvil con brinco de un periodo. Con los pronósticos de los dos métodos se estableció un rango entre 68,06 y 14. Como resultado tenemos que el intervalo entre los dos pronósticos es muy holgado, aminorando la confianza en los pronósticos y cuyo origen es el punto atípico tan grande.




Gráfico 4. Gráfica de análisis de tendencia exponencial del producto "a". (Elaboración propia).

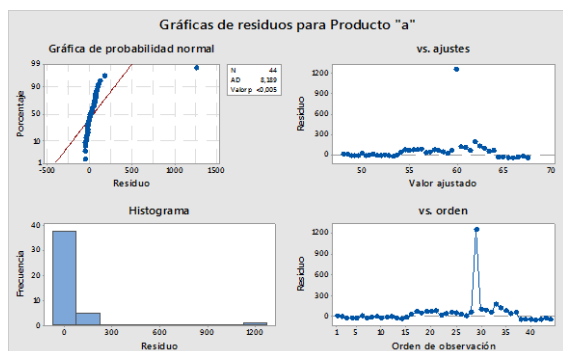


Gráfico 5. Gráfica de residuos de tendencia exponencial del producto "a". (Elaboración propia).




Gráfico 6. Gráfica de promedio móvil con longitud estacional de 1 periodo del producto "a". (Elaboración propia).

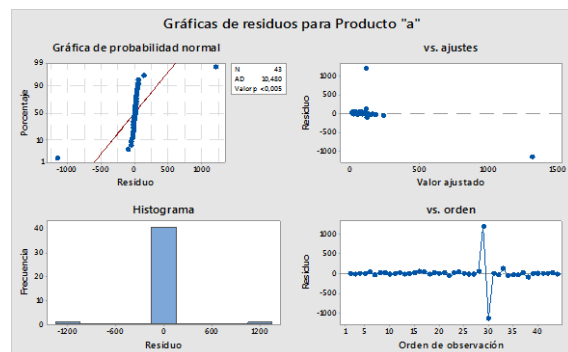


Gráfico 7. Gráfica de residuos de promedio móvil con longitud estacional de 1 periodo del producto "a". (Elaboración propia).

En las gráficas 5 y 7 de residuos se denota que para ambos casos existe una no normalidad con un *valor p* menor a 0,005 junto a la completa ausencia de homocedasticidad. El MAPE del promedio móvil se acopla mejor que el de la tendencia exponencial.

### Análisis del producto "a" sin dato atípico




Gráfico 8. Gráfica del producto "a" sin datos anormales. (Elaboración propia).



Sin el dato atípico, la mejor técnica de modelo causal es la tendencia cuadrática y en series de tiempo cambió al promedio móvil con longitud estacional tres, dando un nuevo rango entre 23,57 y 21,33. El resultado es un intervalo entre los pronósticos mucho menos holgado que el anterior análisis y con una normalidad de los datos bastante robusta en contraste con la anterior.




Gráfico 9. Gráfica de análisis de tendencia cuadrática del producto "a". (Elaboración propia).

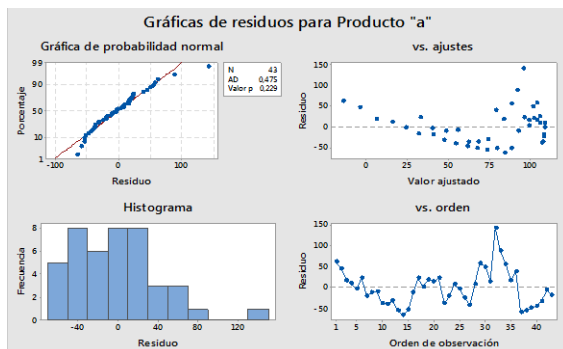


Gráfico 10. Gráfica de residuos de tendencia cuadrática del producto "a". (Elaboración propia).




Gráfico 11. Gráfica de promedio móvil de longitud estacional de 3 periodos del producto "a". (Elaboración propia).

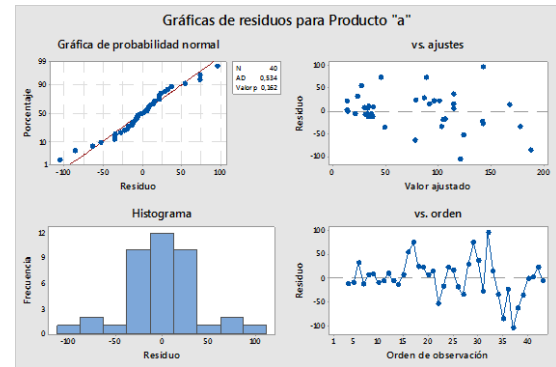


Gráfico 12. Gráfica de residuos de promedio móvil de longitud estacional de 3 periodos del producto "a". (Elaboración propia).

En las gráficas 10 y 12 de residuos se aprecia una clara normalidad de ambos métodos, pero con un *valor p* elevado de 0,229 en el análisis de tendencia cuadrática, a comparación de un 0,162 del promedio móvil. La homocedasticidad es mejor en la tendencia cuadrática. El MAPE es significativamente más bajo en el promedio móvil con 67,79 respecto al 93,17 de la cuadrática. Se escogió el promedio móvil con brinco de tres periodos de entre los que tenían menor MAPE debido a su normalidad mayor a uno.

## Discusión


Con los resultados obtenidos y la interpretación de las gráficas se recomienda examinar la información sin el dato anómalo debido a que este altera de forma circunstancial el análisis estadístico, quitando normalidad a los datos. Si se necesita escoger solo uno de entre los dos métodos que se adaptaron mejor al producto *a*, se recomienda tomar el análisis de tendencia cuadrática a pesar de que tiene el MAPE más grande, debido a que su normalidad es elevada lo que haría a este método bastante robusto y

menos propenso a errores al momento de realizar pronósticos; se recomienda tomar el intervalo generado entre los dos pronósticos como el rango de producción debido a la fiabilidad que presentan los mismos. El punto pronosticado se encuentra en la parte baja de una ciclicidad que se aprecia en la distribución de la serie de datos junto con estacionalidad. En

el Anexo 3 se podrá observar la corroboración del análisis realizado a este producto con el modelamiento planteado.

### Producto “b”

Este producto fue un caso que presentaba tres datos fuera de lugar.



Se realizó el mismo procedimiento que el producto *a* comenzando con la gráfica de caja (cuartiles), encontrando cuatro datos atípicos o disruptores siendo estos 8920,28, 2229, 223 y -55,54 pertenecientes a noviembre del 2016, octubre del 2015, diciembre del 2016 y febrero del 2017 correspondientemente.

Por lo tanto, se examinó la serie con y sin estos datos a excepción del valor 223, que a pesar de salir en la gráfica de cajas como no

normal si formaba parte de la serie de datos ya que era parte de un pico normal.



Tabla 4. Resultados del Producto "b" en Minitab®. (Elaboración propia).

Producto	Intervalo de Confianza Superior	Pronóstico	Intervalo de Confianza Inferior	N	Valor p	Longitud Estacional	Método Estadístico	Periodo	MAPE	Ecuación	
b		659,56		44	<0,005	-	T. L.	1	497	$Y_t = -22 + 15,1 \times t$	CAUSALES
			N/A				T. E.		N/A		
		530,89		44	<0,005	-	T. C.	1	539	$Y_t = -150 + 31,9 \times t - 0,37 \times t^2$	
		264,26		44	<0,005	15	D. E.	1	757	$Y_t = -103 + 18,3 \times t$	
		229,67		44	<0,005	14	D. E.	1	721	$Y_t = -16 + 15,8 \times t$	
		315,57		44	<0,005	13	D. E.	1	428	$Y_t = -7 + 15,7 \times t$	SERIES DE TIEMPO
	3939,64	110	-3719,4	43	<0,005	1	P. M.	1	293	-	
	3464,43	91	-3282,4	42	<0,005	2	P. M.	1	356	-	
	3316,56	81,33	-3153,9	41	<0,005	3	P. M.	1	427	-	
	1107,47	245,37	-616,72	44	<0,005	-	S. O. E. $\alpha=0,013$	1	213	-	
	1496,33	314,62	-867,09	44	<0,005	-	S. E. $\alpha=0,2$	1	369	-	
	1363,1	97,9	-1167,31	44	<0,005	-	S. E. $\alpha=0,5$	1	356	-	
	1389,4	102,14	-1185,13	44	<0,005	-	S. E. $\alpha=0,8$	1	303	-	
b sin Valores Atípicos o Disruptivos		70,27		41	<0,005	-	T. L.	1	52,5	$Y_t = 73,3 - 0,072 \times t$	CAUSALES
		57,15		41	<0,005	-	T. E.	1	43,6	$Y_t = 68,683 \times (0,99563^t)$	
		94,59		41	<0,005	-	T. C.	1	46,42	$Y_t = 97,6 - 3,47 \times t + 0,0808 \times t^2$	
		76,82		41	<0,005	16	D. E.	1	47,65	$Y_t = 74,2 - 0,139 \times t$	
		119,71		41	0,225	15	D. E.	1	43,11	$Y_t = 74,7 - 0,123 \times t$	SERIES DE TIEMPO
		50,63		41	0,078	14	D. E.	1	37,66	$Y_t = 77,3 - 0,279 \times t$	
		90,33		41	<0,005	13	D. E.	1	42,43	$Y_t = 73,8 - 0,120 \times t$	
	227,9	110	-7,9	40	0,014	1	P. M.	1	63,94	-	
	196,6	91	-14,6	39	0,025	2	P. M.	1	61,76	-	
	180,91	81,33	-18,24	38	<0,005	3	P. M.	1	59,62	-	
			N/A				S. E. Ó.		N/A		
	156,59	80,52	4,45	41	<0,005	-	S. E. $\alpha=0,2$	1	51	-	
	172,92	90,42	7,92	41	<0,005	-	S. E. $\alpha=0,5$	1	53,65	-	
	143,96	102,14	10,33	41	0,019	-	S. E. $\alpha=0,8$	1	58,85	-	

\*T.L. = Tendencia Lineal; T.E. = Tendencia Exponencial; T.C. = Tendencia Cuadrática; D.E. = Descomposición Estacional; P.M. = Promedio Móvil; S.E.O. = Suavizamiento Exponencial Óptima calculada por Minitab®; S.E. = Suavizamiento Exponencial.

El análisis de la tabla 4 del producto *b* es similar al de la tabla 3 del producto *a*, por lo tanto, la explicación de la tabla 4 será la misma, con el contraste en la obtención de diferentes resultados de los métodos adecuados para el producto *b*.

#### *Análisis del producto "b" con dato atípico*

Apreciando la tabla 4 de resultados notamos que para *b* con datos anómalos la regresión más favorable era la lineal con descomposición de longitud estacional 13, y la de mejor adaptación para la serie de tiempos era el de suavizamiento exponencial óptimo, estimado por Minitab®, con  $\alpha = 0,013$ . Los

pronósticos de estas técnicas dieron un intervalo entre 315,57 y 245,37. Como en el caso del producto *a*, la holgura entre los dos extremos es demasiado grande debido al ruido estadístico que generan los varios datos atípicos o disruptivos presentes en la serie de datos.




Gráfico 16. Gráfica de descomposición con longitud estacional de 13 periodos del producto "b". (Elaboración propia).

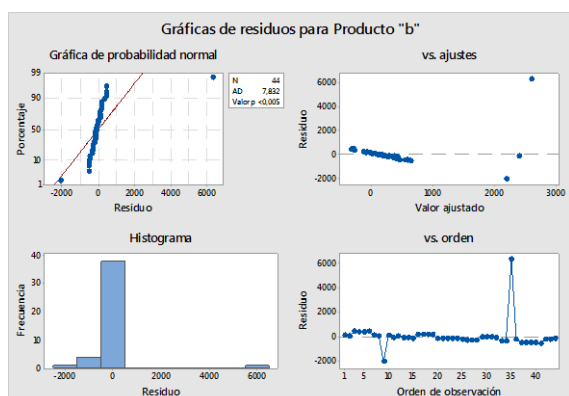


Gráfico 17. Gráfica de residuos de descomposición con longitud estacional de 13 periodos del producto "b". (Elaboración propia).




Gráfico 18. Gráfica de suavización exponencial con  $\alpha$  óptimo del producto "b". (Elaboración propia).

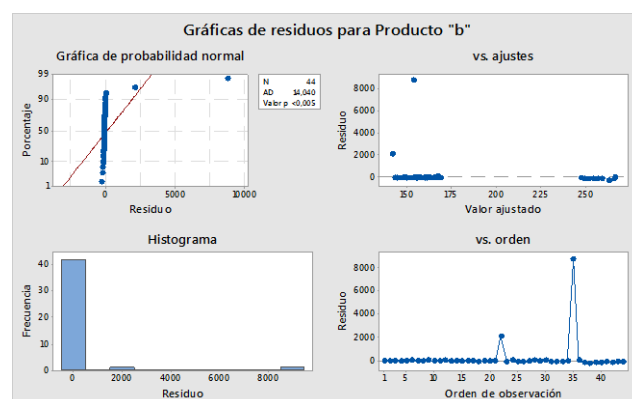


Gráfico 19. Gráfica de residuos de suavización exponencial con  $\alpha$  óptimo del producto "b". (Elaboración propia).

Las gráficas 17 y 19 de residuos de ambos casos señalan claramente los puntos que no permiten la normalidad, teniendo en ambas un *valor p* menor a 0,005 y completa ausencia de homocedasticidad. El MAPE del suavizamiento es menor que el de la descomposición, acoplándose mejor a la disposición de los datos.

### *Análisis del producto "b" sin dato atípico*




Gráfico 20. Gráfica del producto “b” sin datos anormales. (Elaboración propia).

Tomando el producto  $b$  sin los puntos anómalos tenemos un cambio radical en los resultados de los métodos, siendo la descomposición con longitud estacional a 15 periodos el más apropiado para regresiones, y para series de tiempo se acopla mejor el suavizamiento exponencial con  $\alpha = 0,8$ , facilitando un nuevo rango entre 119,71 y 102,14. A pesar de que la descomposición de 14 periodos tenía un menor MAPE, la normalidad o *valor p* era sustancialmente más grande y mayor a 1 con 15 periodos brindando más robustez estadística, razón por la cual se seleccionó la descomposición con longitud de 15 periodos.




Gráfico 21. Gráfica de descomposición con longitud estacional de 15 periodos del producto “b”. (Elaboración propia).

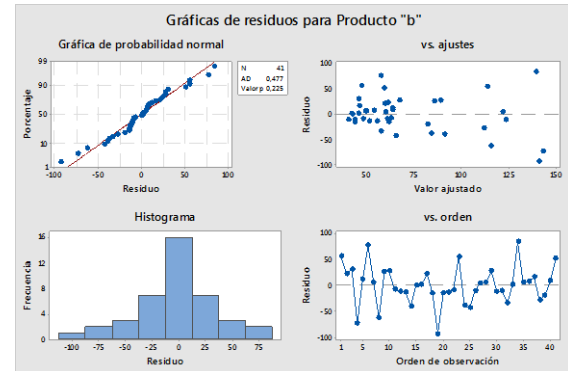


Gráfico 22. Gráfico de residuos de descomposición con longitud estacional de 15 periodos producto “b”. (Elaboración propia).




Gráfico 23. Gráfico de suavización exponencial con  $\alpha=0,8$  producto “b”. (Elaboración propia).

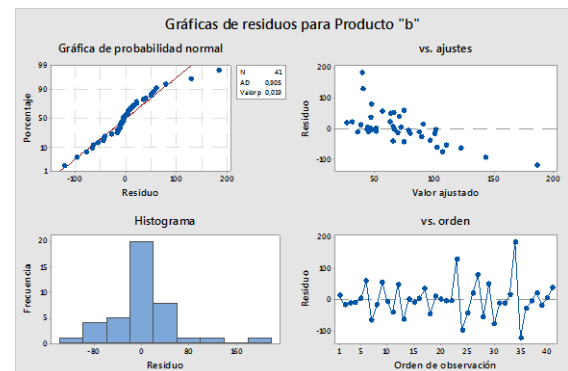


Gráfico 24. Gráfica de residuos de suavización exponencial con  $\alpha=0,8$  producto “b”. (Elaboración propia).

## Discusión

Una vez examinados los resultados de las pruebas y gráficas 22 y 24 obtenidos en el análisis del producto  $b$ , se recomienda moldear la información sin los datos atípicos o disruptivos puesto que esos tres puntos no

permiten un estudio correcto de los valores alterando su normalidad, homocedasticidad y tendencias, perturbando los valores de los pronósticos que se desean obtener. Entre los dos métodos que se adaptaron mejor al producto *b*, el análisis de descomposición estacional a 15 periodos de longitud estacional es el mejor porque es más robusto y el menos propenso a errores, debido a que presenta el MAPE más bajo, la normalidad más alta y una buena homocedasticidad. También, el producto presenta ciclicidad en su serie de datos, que se aprecia en la disposición de su curva. Para un mejor manejo en la producción

se recomienda tomar el rango generado entre los dos pronósticos debido a la fiabilidad de las pruebas estadísticas. En el Anexo 4 se podrá observar la corroboración del análisis realizado a este producto con el modelamiento planteado.

### Producto “d”

El producto presenta una tendencia estacional bastante ceñida con picos altos muy marcados, pero también presenta un dato demasiado fuera de rango en el periodo 22, perteneciente a octubre del 2015, el cual altera la tendencia de la serie de datos.




Gráfico 25. Demanda Real Unificada producto “d”. (Elaboración propia).




Gráfico 26. Demanda Real Anual producto “d”. (Elaboración propia).

Se moldearon los datos mediante la gráfica de caja (cuartiles) encontrando dos datos atípicos o disruptores siendo estos 1533

y 224 pertenecientes a octubre del 2015 y diciembre del 2014 correspondientemente.

Por consiguiente, se realizó el estudio con y sin el valor de 1533, pero todavía considerando el dato de 224 debido a que es un pico que se mantiene dentro de la tendencia.

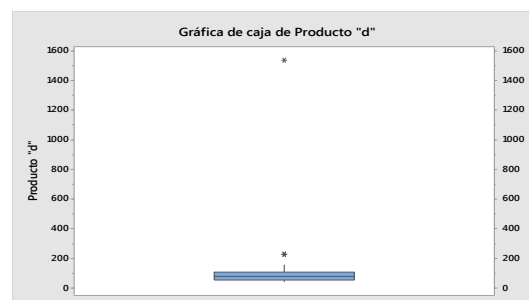


Gráfico 27. Gráfica de caja, producto "d". (Elaboración propia).

Tabla 5. Resultados del Producto "d" en Minitab®. (Elaboración propia).

Producto	Intervalo de Confianza Superior	Pronóstico	Intervalo de Confianza Inferior	N	Valor p	Longitud Estacional	Método Estadístico	Periodo	MAPE	Ecuación	
d		95,38		44	<0,005	-	T. L.	1	71,6	$Y_t = 139,2 - 0,97 \times t$	CAUSALES
		64,77		44	<0,005	-	T. E.	1	38,9	$Y_t = 103,410 \times (0,98966^t)$	
		24,16		44	<0,005	-	T. C.	1	85,3	$Y_t = 68 + 8,3 \times t - 0,206 \times t^2$	
		48,14		44	<0,005	15	D. E.	1	97,6	$Y_t = 140,1 - 1,06 \times t$	
		79,26		44	<0,005	14	D. E.	1	64,2	$Y_t = 143,2 - 1,13 \times t$	
		62,41		44	<0,005	13	D. E.	1	69,8	$Y_t = 141,3 - 0,97 \times t$	SERIES DE TIEMPO
	742,2	109	-524,19	43	<0,005	1	P. M.	1	109	-	
	630,9	95,5	-439,94	42	<0,005	2	P. M.	1	86,2	-	
	600,7	79,33	-442,02	41	<0,005	3	P. M.	1	94,2	-	
	271,3	102,2	-66,86	44	<0,005	-	S. E. Ó $\alpha=0,010$	1	56,6	-	
d sin Valores Atípicos o Disruptivos	296,3	82,01	-132,29	44	<0,005	-	S.E. $\alpha=0,2$	1	85,8	-	CAUSALES
	319,6	91,9	-135,78	44	<0,005	-	S.E. $\alpha=0,5$	1	88,7	-	
	335,9	102,63	-130,62	44	<0,005	-	S.E. $\alpha=0,8$	1	94,4	-	
	64,26			43	<0,005	-	T. L.	1	39,18	$Y_t = 104,5 - 0,914 \times t$	
	60,49			43	<0,005	-	T. E.	1	33,8	$Y_t = 96,619 \times (0,98941^t)$	
	81,64			43	<0,005	-	T. C.	1	36,33	$Y_t = 121,9 - 3,23 \times t + 0,0527 \times t^2$	SERIES DE TIEMPO
	61,05			43	0,469	15	D. E.	1	31,98	$Y_t = 109,8 - 1,173 \times t$	
	33,75			43	0,299	14	D. E.	1	32,88	$Y_t = 109,3 - 1,134 \times t$	
	44,26			43	0,006	13	D. E.	1	35,48	$Y_t = 106,3 - 1,014 \times t$	
	226,7	109	-8,67	42	<0,005	1	P. M.	1	49,71	-	
	201,7	95,5	-10,75	41	0,126	2	P. M.	1	51,05	-	CAUSALES
	178,5	79,33	-19,81	40	0,034	3	P. M.	1	50,36	-	
			N/A				S. E. Ó	N/A		-	
	163,4	79,85	-3,69	43	<0,005	-	S.E. $\alpha=0,2$	1	44,25	-	
	179	91,9	4,8	43	0,007	-	S.E. $\alpha=0,5$	1	45,05	-	
	192,5	102,63	12,77	43	<0,005	-	S.E. $\alpha=0,8$	1	46,56	-	

\*T.L. = Tendencia Lineal; T.E. = Tendencia Exponencial; T.C. = Tendencia Cuadrática; D.E. = Descomposición Estacional; P.M. = Promedio Móvil; S.E.O. = Suavizamiento Exponencial Óptima calculada por Minitab®, S.E. = Suavizamiento Exponencial.



El análisis de la tabla 5 del producto *d* es similar al de la tabla 3 del producto *a*, por lo tanto, la explicación de la tabla 5 será la misma, con el contraste en la obtención de diferentes resultados de los métodos adecuados para el producto *d*.

### Análisis del producto "d" con dato atípico

Los datos de la tabla 5 nos enseñan que para el producto *d* con el dato atípico o disruptor el mejor método de regresión para su situación es la tendencia exponencial y en series de tiempo la mejor técnica es el suavizamiento exponencial óptimo con  $\alpha = 0,010$ , generando un rango para el pronóstico entre 102,2 y 52,34. La holgura entre los datos es demasiado grande debido a la presencia del dato disruptor.




Gráfico 28. Tendencia exponencial producto "d". (Elaboración propia).




Gráfico 29. Gráfica de residuos de tendencia exponencial de producto "d". (Elaboración propia).




Gráfico 30. Gráfica de suavización exponencial con  $\alpha$  óptimo=0,010 del producto "d". (Elaboración propia).




Gráfico 31. Gráfico de residuos de suavización exponencial  $\alpha$  óptimo=0,010 del producto "d". (Elaboración propia).

Se puede observar claramente en las pruebas estadísticas de las gráficas 29 y 31 que el grupo de datos carecen de normalidad y homocedasticidad debido a un valor que no corresponde. Además, tanto el *valor p* menor a 0,005 en ambos métodos, como la amplia holgura, corroboran que no hay algo extraño en los valores. Entre los dos métodos el que mejor se acopla es la tendencia exponencial.

### Análisis del producto "d" sin dato atípico






Gráfico 32. Gráfica de producto “d” sin datos anormales. (Elaboración propia).

El producto *d* sin el dato atípico o disruptor presenta un comportamiento totalmente diferente a comparación con su análisis anterior. Se aprecia que el modelo causal que mejor se adapta a los datos es la descomposición estacional con 15 periodos de longitud estacional, mientras que el mejor modelo de series de tiempo es el promedio móvil a dos periodos. Estos modelos nos entregan un rango para el pronóstico del siguiente periodo entre 61,05 y 95,5. Se prefirió la descomposición con longitud estacional de 15 periodos con un MAPE ligeramente mayor, sobre la de 14 periodos, debido a que conseguía una normalidad estadística o *valor p* elevado y mejor que con 14 periodos.




Gráfico 33. Gráfica de descomposición con 15 periodos de longitud estacional del producto “d”. (Elaboración propia).

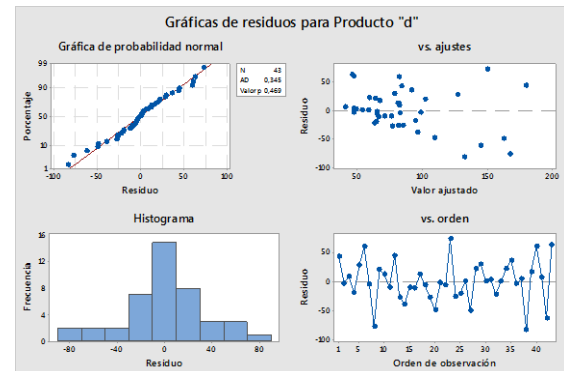


Gráfico 34. Gráfica de residuos de descomposición con longitud estacional de 15 periodos del producto “d”. (Elaboración propia).




Gráfico 35. Gráfica de promedio móvil con longitud estacional de 2 periodos del producto “d”. (Elaboración propia).

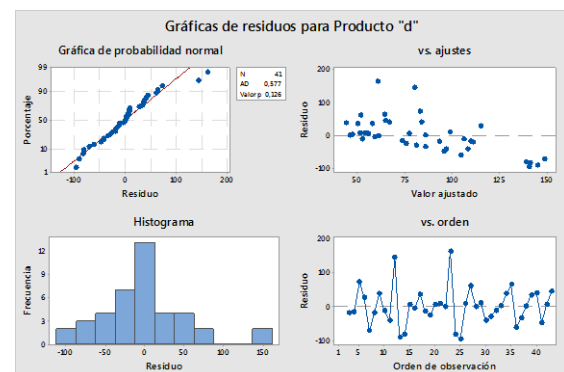


Gráfico 36. Gráfica de residuos de promedio móvil con longitud estacional de 2 periodos producto “d”. (Elaboración propia).

## Discusión

Una vez examinados las gráficas 34 y 36 con los datos y pruebas obtenidos en el análisis del

producto *d*, se recomienda moldear la información sin los datos atípicos o disruptivos puesto que estos puntos no permiten un estudio correcto de los datos alterando su normalidad, homocedasticidad y tendencias, perturbando los valores de los pronósticos que se desean obtener.

Entre los dos métodos que se adaptaron mejor al producto *d*, el análisis de descomposición estacional a 15 periodos es el mejor porque es más robusto y el menos propenso a errores, debido a que presenta un MAPE bajo, la normalidad más alta entre los dos métodos y una buena homocedasticidad. También presenta estacionalidad y ciclicidad en su serie de datos; la ciclicidad se puede observar a lo largo de la serie haciendo énfasis

en el repunte de los últimos periodos. Se recomienda tomar el rango generado por los dos pronósticos para un mejor manejo en la producción debido a la confiabilidad de los datos. En el Anexo 5 se podrá observar la corroboración del análisis realizado a este producto con el modelamiento planteado.

### Producto “k”

Este no poseía datos anómalos dentro de sus series de datos sino todo lo contrario, mostraban valores con marcada estacionalidad, tendencia y ciclicidad, que, sin datos atípicos o disruptivos, se podían modelar en mejores condiciones y con mayor rapidez, facilitando la obtención de resultados.




Gráfico 37. Demanda Real Unificada producto “k”. (Elaboración propia).




Gráfico 38. Demanda Real Anual producto “k”. (Elaboración propia).

Se examinaron los datos mediante la gráfica de caja (cuartiles) para apreciar que no existen datos atípicos o disruptores y que todos se encuentran en un rango normal propio de su serie.

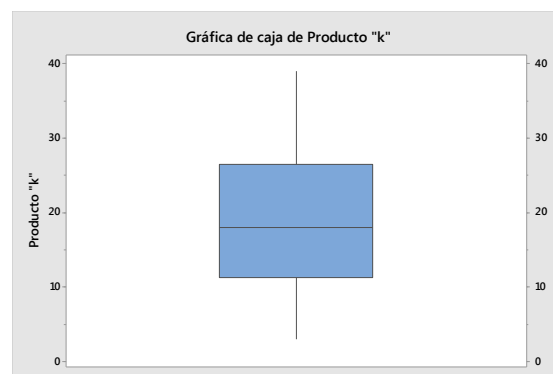


Gráfico 39. Gráfico de caja, producto “k”.  
(Elaboración propia).

Tabla 6. Resultados del producto "k" en Minitab®. (Elaboración propia).

Producto	Intervalo de Confianza Superior	Pronóstico	Intervalo de Confianza Inferior	N	Valor p	Longitud Estacional	Método Estadístico	Periodo	MAPE	Ecuación	
k		13,25		44	<0,005	-	T. L.	1	57,81	$Y_t = 27,57 - 0,318 \times t$	CAUSALES
		11,09		44	<0,005	-	T. E.	1	46,78	$Y_t = 27,598 \times (0,97995^t)$	
		18,37		44	<0,005	-	T. C.	1	55,16	$Y_t = 32,70 - 0,987 \times t + 0,0149 \times t^2$	
		11,6		44	0,272	16	D. E.	1	43,54	$Y_t = 28,43 - 0,357 \times t$	
		21,65		44	0,329	15	D. E.	1	44,3	$Y_t = 29,04 - 0,374 \times t$	
		5,7		44	0,836	14	D. E.	1	48,43	$Y_t = 28,38 - 0,3594 \times t$	SERIES DE TIEMPO
		35,52	10	43	0,258	1	P. M.	1	61,35	-	
		36,55	13,5	42	0,533	2	P. M.	1	63,41	-	
		40,33	17	41	0,038	3	P. M.	1	75,59	-	
		38,23	16,97	44	<0,005	-	S. E. Ó $\alpha=0,057$	1	65,4	-	
		37,66	16,62	44	<0,005	-	S. E. $\alpha=0,2$	1	63,35	-	
		36,41	14,36	44	0,024	-	S. E. $\alpha=0,5$	1	61,32	-	
		34,81	11,6	44	0,209	-	S. E. $\alpha=0,8$	1	59,83	-	

\*T.L. = Tendencia Lineal; T.E. = Tendencia Exponencial; T.C. = Tendencia Cuadrática; D.E. = Descomposición Estacional; P.M. = Promedio Móvil; S.E.O. = Suavizamiento Exponencial Óptima calculada por Minitab®; S.E. = Suavizamiento Exponencial.

El análisis de la tabla 6 del producto *k* es similar al de la tabla 3 del producto *a*, por lo tanto, la explicación de la tabla 6 será la misma, con el contraste en la obtención de diferentes resultados de los métodos adecuados para el producto *k*.

### Análisis del producto “k”

En la tabla de resultados se puede observar que métodos se acoplan mejor a la serie de datos

del producto. De los modelos causales el más apropiado es la descomposición con longitud estacional de 16 periodos, mientras que en modelos de series de tiempo el de mejor adaptación es el suavizamiento exponencial con  $\alpha = 0,8$ . Los pronósticos de estos dos modelos abren un intervalo de confianza de cero, el cual es bastante ajustado y confiable debido a la alta normalidad que poseen ambas técnicas, pero a la vez no otorga un rango en el

que se pueda manejar la producción con seguridad de corrección.

Tanto la descomposición con longitud estacional de 16 periodos como el promedio móvil de longitud estacional de dos periodos tienen el MAPE más bajo entre sus respectivos modelos, y tienen un *valor p* alto, lo que denota normalidad entre los datos, siendo esto un factor estadístico que marca robustez en la serie de datos.




Gráfico 40. Gráfica de descomposición con 16 periodos de longitud estacional del producto "k". (Elaboración propia).

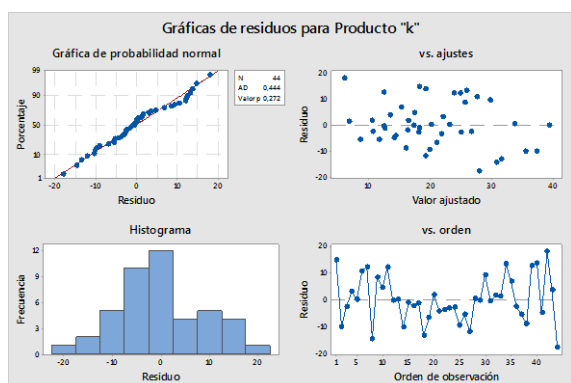


Gráfico 41. Gráfica de residuos de descomposición con longitud estacional de 16 periodos del producto "k". (Elaboración propia).




Gráfico 42. Gráfica de promedio móvil con longitud estacional de 2 periodos del producto "k". (Elaboración propia).

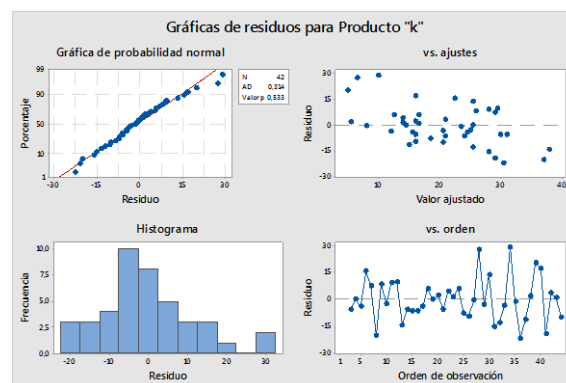


Gráfico 43. Gráfica de residuos de promedio móvil con longitud estacional de 2 periodos del producto "k". (Elaboración propia).

## Discusión

Es fácil percatarse que el producto *k*, cumple con todas las pruebas estadísticas para ser un conjunto de datos estadísticamente normales, gracias a su elevado *valor p*, el acoplamiento de los puntos sobre la línea de distribución normal y una excelente homocedasticidad en los dos métodos. Todo esto sin tener que alterar su serie de datos.

Una vez realizado el estudio al producto *k* se puede decir con mayor certeza que presenta estacionalidad y ciclicidad, aseverando que, el método que mejor se acopló a sus valores fue la regresión con descomposición lineal de

longitud estacional de 16 periodos. En este caso en el que los dos pronósticos coincidieron exactamente, se recomienda tomar en los métodos de series de tiempo el promedio móvil con longitud estacional de dos periodos debido a que presenta la normalidad más alta entre todos los métodos dando confiabilidad en el pronóstico del siguiente periodo. En el Anexo 6 se podrá observar la corroboración

del análisis realizado a este producto con el modelamiento planteado.

Finalmente, tenemos al algoritmo desarrollado durante todo el análisis estadístico que funcionó y sirvió como guía en todo el proceso de estudio para determinar el mejor método estadístico para manejar la fluctuación de la demanda en PYMES.

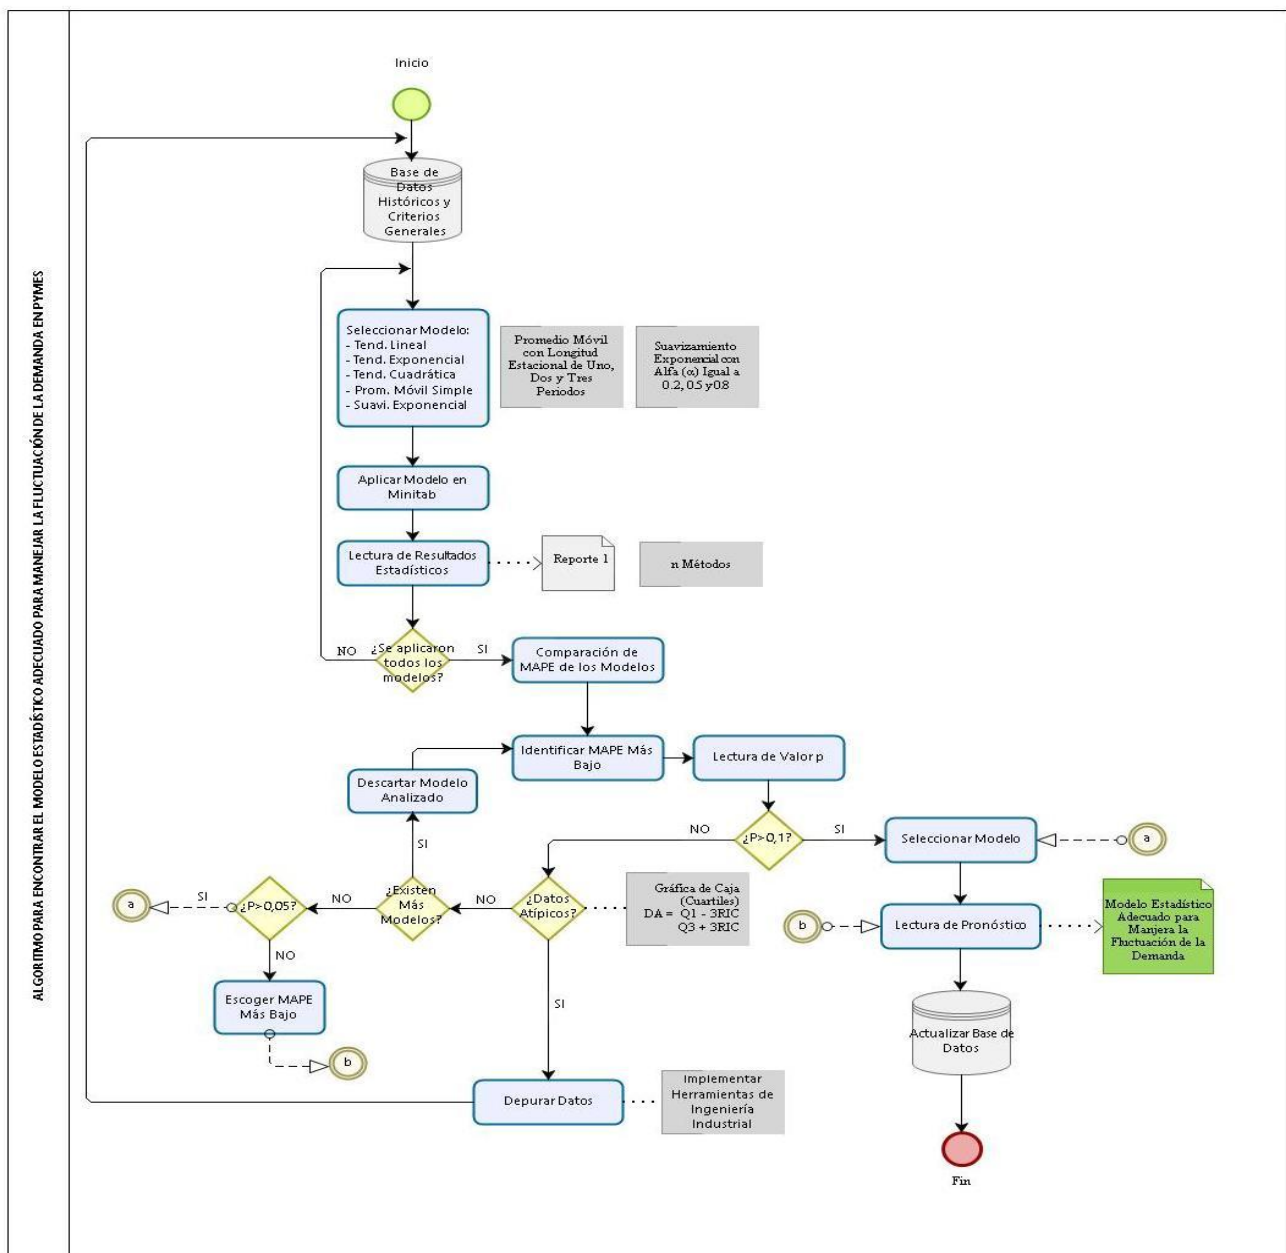


Figura 8. Algoritmo para seleccionar el modelo estadístico adecuado para manejar la fluctuación de la demanda en PYMES. (Elaboración propia).

Como acotación, con los resultados de los cuatro productos estudiados, se recopilamos los parámetros obtenidos en todos los análisis generando una tabla acumulada que compara todos los métodos aplicados en cada producto (Anexo 1) junto con la tabla de los resultados de las gráficas de cuartiles de todos los productos (Anexo 2). En el anexo 3 se muestra la gráfica de los cuatro productos analizados con sus correspondientes datos anómalos, y en el anexo 4 se presenta la gráfica sin los datos anómalos, todo esto para fines comparativos.

#### 4. Conclusiones

El algoritmo al ser desarrollado mediante el análisis estadístico de los cuatro productos demostró funcionar con éxito en todos ellos, corroborando que con los parámetros establecidos de forma correcta se puede determinar un adecuado método estadístico para pronosticar.

Como medida de robustez del modelo se implementó un valor  $p$  mayor a 0,1 para asegurar que los datos tengan normalidad y homocedasticidad en los métodos que menor MAPE obtengan, y también demostrar una buena calidad en los datos.

El proponer un algoritmo para encontrar el mejor método según el menor error es una forma eficiente de detectar la adaptación de los métodos estadísticos a las diferentes empresas según los productos que estas manejen, ya que el algoritmo dictamina que se repita la modelación de datos hasta encontrar el menor

error de entre los modelos utilizados. Por lo tanto, es así como se va a seleccionar el método estadístico adecuado para manejar la fluctuación de la demanda en PYMES.

Dentro del enfoque cuantitativo, los modelos causales y los modelos de series de tiempo son de enorme ayuda al momento de analizar y estudiar una serie de datos, ya que mediante ellos se pueden apreciar las múltiples variaciones y disposiciones que los datos puedan tener, facilitando la comprensión del comportamiento de un grupo de valores que en este caso representaban varios productos.

Las tendencias exponenciales generalmente aparecen con un menor error en los resultados debido a que se acoplan mejor a la disposición de los datos con tendencias.

Los métodos estadísticos aquí expuestos pronosticaron máximo hasta un periodo hacia adelante con un gran nivel de confianza del 95%, ya que no se puede predecir el futuro; pero en lo que sí ayuda predecir más de un periodo es a mostrar la tendencia que los pronósticos van a seguir.

No se pueden realizar pronósticos anuales ya que como se necesitarían por lo menos 15 datos de años pasados, el pronóstico no reflejaría la realidad actual del entorno ni de la empresa, por lo que solo se pueden establecer metas de ventas anuales.

Cada modelo tiene sus características propias. Los modelos causales o de regresión

son particularmente buenos para detectar tendencias y comportamientos en el tiempo, pero al momento de usarlos para pronosticar valores futuros no son tan acertados ya que tienden a cargar más los datos generando pronósticos altos. Los modelos de series de tiempo son buenos para pronosticar el siguiente periodo ya que siempre toman los datos más recientes para generar la proyección en el futuro, y lo hacen de forma más cautelosa dando resultados más bajos. Por lo tanto, se sugiere que al momento de generar un pronóstico para el siguiente periodo se utilicen rangos y no datos exactos debido a que así se tendrá una holgura para no provocar desfases en el pronóstico de la demanda. Lo más adecuado sería tener como techo la proyección con los métodos causales o de regresión y como base los métodos de series de tiempo, así como se lo hizo en este estudio.

Se realizó también el modelo en Excel<sup>®</sup> con todos los cuatro productos, pero se prefirieron los modelados mediante el software Minitab<sup>®</sup> para apreciar de mejor manera las gráficas y los resultados que el programa calculaba mediante sus propias pruebas estadísticas.

Generar tablas de resultados de los productos es una manera visual y eficiente de mostrar todos los valores recolectados al moldear los datos, además facilita la selección del modelo apropiado según los parámetros que exhibía la tabla, mostrando cual era la

mejor opción en series de tiempo y métodos causales.

Cuando se presentaron productos con series de datos que contenían valores atípicos o disruptivos, lo mejor fue analizarlos con y sin esos valores para observar el comportamiento del producto, discutir las diferencias y observar como esos datos alteran el estudio estadístico, en especial, las proyecciones.

Al presentarse errores demasiado grandes entre métodos, se hizo un análisis de los datos, encontrando que los causantes de los errores tan grandes eran los datos atípicos o disruptivos.

Como conclusión general para las PYMES se puede decir que existen modelos muy complejos que se pueden resolver mediante sistemas detallados más fuertes, pero que obviamente son mucho más fiables estadísticamente; también hay modelos más suaves que no son tan robustos pero que satisfacen las necesidades de la empresa; por ejemplo, el promedio móvil no es tan robusto, pero no da malos resultados.

Los modelos robustos en general se utilizan para una empresa que necesite un moldeado bastante fuerte de los datos, la cual obviamente necesitará una regresión lineal con tendencia o estacionalidad para identificar los valores, priorizando la normalidad antes que el error MAPE para vigilar que se cumplan las pruebas estadísticas, es decir, que sean



normales, que sean homoscedásticos y que sean aleatorios. Similar a lo realizado en este estudio.

Este estudio se desarrolló mediante Minitab® 18 para todo el proceso estadístico y en Excel® 2016 para ciertas ilustraciones gráficas. Dado que el objetivo de este ensayo académico fue la creación de un algoritmo que pueda funcionar en cualquier situación, también se podría realizar este estudio en Excel® u otro tipo de software libre como “R®”, pero se necesitaría de alguien que tenga un conocimiento más profundo de programación (como c++ para “R®”) y especialmente de estadística, debido a que los análisis estacionales, al igual que el cálculo de los errores, son muy complejos y pesados de realizarlos a mano. De igual manera se debe pensar en la condicionante del dinero para la inversión en un paquete de software estadístico dado que en algunas situaciones las PYMES no cuentan con el capital para invertir en software de pago.

Los modelos podrían haber sido mucho mejores en su adaptación a los productos si se hubiesen removido ciertos datos que también generaban ruido estadístico al momento de analizarlos, pero para eso la persona encargada necesitaría ir a la fuente de los datos para su correspondiente revisión.

El algoritmo puede ser utilizado para posteriores investigaciones estadísticas tanto académicas como empresariales, dejando campo abierto para un estudio posterior del

mismo. También podría servir para programarlo mediante software, ya que, por ahora, su desarrollo es manual.

En este estudio el algoritmo se desarrolló con los datos de una empresa comercializadora catalogada como PYME, por lo que como futuras líneas de investigación se propone aplicar este algoritmo en empresas de naturaleza productiva y de servicios para observar su respuesta y reacción ante otro sector industrial.

Se deben generar bases de datos y no manejar solo reportes ya que estos últimos pueden maquillar la verdadera información de los datos de las empresas, lo que impide claridad en el análisis de la situación real de la empresa. Las bases de datos permiten manejar todos los aspectos dentro de la empresa ya que se inmiscuyen directo en el origen, entregando información verídica en tiempo real de lo que está sucediendo.

Los modelos de series de tiempo como el promedio móvil doble y el promedio móvil ponderado pueden ser aplicados para un estudio similar o como continuación de este, a través del uso de otros paquetes de software para así poder determinar si son necesarios en las PYMES mediante el análisis de los resultados, debido a que son más complejos y, en este caso, el programa no nos permitió analizarlos.

Para esta empresa y en general para las PYMES, se propone la implementación de





herramientas de ingeniería industrial como el árbol de problemas, herramienta 5S, el diagrama de Ishikawa o causa-efecto, entre otros, para analizar el origen y causa de los datos anómalos para poder determinar si se tratan de datos atípicos o disruptores o errores humanos de medición o tipeo, puesto que estadísticamente no existe la suficiente evidencia para determinar porque esos puntos pasaron, caso contrario estos se considerarían variabilidad pura.

Los motivos que pudieron haber generado datos atípicos o disruptores que se presentaron en las series de datos de los productos estudiados deben ser corroborados ya que se podrían deber a cambios gerenciales, cambios estratégicos, pedidos extraordinarios, cambios de políticas estatales, entre otros; por lo tanto, se recomienda implementar, junto a las herramientas de ingeniería industrial, un análisis externo político, económico, social, tecnológico y ambiental (PESTA), para determinar las causas de tales variaciones, en conjunto con la investigación de la fuente de los mismos y proponiendo métodos para manejarlos.

### Agradecimientos

A Dios y a la Virgen Dolorosa por iluminarme y protegerme bajo su manto sagrado.

A mi madre Marcita por su amor incondicional durante todos estos años y forjar al hombre que soy ahora.

A mi novia Mayra por toda su ayuda, su paciencia, su apoyo, su amor y por nunca dejar de creer en mí.

A Tuta por siempre llenarme de alegría.

A todos mis locos amigos, “thanks for the memories and let this wild journey never end”.

A la empresa comercializadora por contribuir con la información para este estudio.

Al Ingeniero Jonnatan Avilés por todo su conocimiento, tiempo y esfuerzo invertidos.

Al Ingeniero Rodrigo Guamán por sacar adelante este proyecto con toda su ayuda, consejos y tutela.

<<SER MÁS PARA SERVIR MEJOR>>

### Referencias Bibliográficas

- Alzate, D., Aldana, J., & Herdández, F. (2016). Comparación de pruebas de homocedasticidad vía simulación. *XXVI Simposio Internacional de Estadística 2016*. Medellín.
- Arrendondo, F., & Vázquez, J. (2013). *Un modelo de análisis racional para la toma de decisiones gerenciales, desde la perspectiva elsteriana*. Cuadernos de Administración.
- Avalos, I. (2010). *Repositorio de la Universidad Autónoma de Nayarit*. Obtenido de <http://correo.uan.edu.mx/~iavalos/FP/FP1.html>



- Balderrama, C. (2011). *Metodología de la programación*. México.
- Beltrán, E. (2013). *ESTRATEGIA DE MEJORAMIENTO DE LOS MODELOS DE PRONÓSTICOS DE LA DEMANDA CON EL FIN DE OPTIMIZAR LA GESTIÓN LOGÍSTICA DE REPUESTOS AUTOMOTRICES*. Bogota, Colombia: Universidad Militar Nueva Granada.
- Berlanga, V., & Vilá, R. (2014). Cómo obtener un Modelo de Regresión Logística Binaria con SPSS. *Revista d'innovació i Recerca en educació*.
- Bolaños, V. (2013). *utecno.files.wordpress*. Obtenido de <https://utecno.files.wordpress.com/2013/06/metodos-cuant-y-cual1.pdf>
- Calderón, I., & García, A. (2006). *Modelo de un pronóstico estadísticos de siniestros del seguro de gastos médicos mayores individual*. Puebla, México.: Universidad de las Américas.
- Contreras, A., Atziry, C., Martinez, J., & Sánchez, D. (2016). Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos perecederos. *Estudios Gerenciales*, 387-396.
- Corres, G., Passoni, L., Zárate, C., & Esteban, A. (2014). Estudio comparativo de modelos de pronóstico de Ventas. *Revista Iberoamericana de Ingeniería Industrial*, 113-134.
- Cuenca, V. (2011). Regresión Logística. *Revista Varianza*, 9-11.
- Erossa, V. (2004). *Proyectos de inversion en ingeniería: su metodología*. México D.F.: Limusa.
- Esparza, R. (2008). *Estudio de Mercado*. Perú.
- Hanke, J. E., & Wichern, D. W. (2010). *Pronósticos en los Negocios*. México D.F.: PEARSON Prentice Hall.
- Heizer, J., & Render, B. (2009). *Administración de Operaciones*. México: Pearson Educación.
- Hossein, A. (2015). *Time-Critical Decision Making*. Obtenido de <http://home.ubalt.edu/ntsbarsh/stat-data/Forecast.htm>
- Martínez, C. (2012). *Estadística y muestreo*. Bogotá: Ecoe Ediciones.
- Martínez, J. (2007). *Estadística y Probabilidad*. Valencia, España.
- Masini, J., & Vazquez, F. (2014). *Compendio de los modelos cuantitativos de pronósticos*. Obtenido de <https://books.google.com.mx/>
- Molina, J. G., & Rodrigo, M. F. (2010). *OpenCourseWare-Universitat id Valencia*. Obtenido de



[http://ocw.uv.es/ciencias-de-la-salud/pruebas-1/1-3/t\\_01.pdf](http://ocw.uv.es/ciencias-de-la-salud/pruebas-1/1-3/t_01.pdf)

Montero, C. (2011). "PRONÓSTICO DE LA CALIDAD DEL AIRE EN EL ÁREA METROPOLITANA DE LA CIUDAD DE MÉXICO A TRAVÉS DEL ANÁLISIS DE LAS SERIES DE TIEMPO DE LOS COMPONENTES DEL IMECA". México DF: Universidad Iberoamericana.

Moreno, E. (2008). Predicción con series de tiempo y regresión. *Panorama No. 4. Tecnologías de sistemas para pymes.*

Ortiz, S., Segura, J., & Cedeño, R. (2005). MÉTODOS NUMÉRICOS APLICADOS A LA INGENIERÍA. *Ciencia & Desarrollo.*

Pindyck, R., & Rubinfeld, D. (2001). *Econometría, modelos y pronósticos.* . México D.F.: McGraw Hill.

PYME. (2017). *revista PYME.* Obtenido de [revistapyme.com](http://revistapyme.com):  
<http://revistapyme.com/2017/05/18/pronostico-de-la-demanda/>

Quijada, M. J., & Banda, J. M. (2011). *Manual de regresiones.* Puebla-Mexico.

Sánchez, G. (2009). *LA ESTADÍSTICA APLICADA AL ANÁLISIS ECONÓMICO.* Obtenido de <http://www.economia.unam.mx/profesor/barajas/estadis/parte2.pdf>

Sierra, A. M. (2013). *Pronóstico de la demanda.* Obtenido de Wikispaces: <http://pronosticos-de-la-demanda.wikispaces.com/file/view/pronosticodelademanda.pdf>

Vilar, J. (2006). *Estadística 2.* Obtenido de Universidad da Coruña: [http://dm.udc.es/assignaturas/estadistica2/estadistica\\_2.htm](http://dm.udc.es/assignaturas/estadistica2/estadistica_2.htm)

Webster, A. (2011). *Estadística aplicada a los negocios y la economía.* McGraw-Hill.



# ANEXOS



## Anexo 1

Tabla acumulada comparativa de todos los métodos aplicados en cada producto analizado

Producto	Pronóstico			N	AD	Valor p	Long- Estacional	Método Estadístico	Periodo	MAPE	MAD	MSD	Ecuación	CAUSALES
a	150,6			44	8,11	<0,005	-	Tendencia Lineal	1	192,4	72,4	36296,8	$Y_t = 52,0 + 2,19 \times t$	
	68,06			44	8,19	<0,005	-	Tendencia Exponencial	1	102,9	71,9	38755,6	$Y_t = 47,572 \times (1,0080^t)$	
	22,94			44	8,34	<0,005	-	Tendencia Cuadrática	1	145,2	73,6	33453	$Y_t = -75,6 + 18,84 \times t - 0,370 \times t^2$	
	124,84			44	5,06	<0,005	17	Descomposición Estacional	1	160,8	67,1	19412,8	$Y_t = 49,4 + 2,77 \times t$	
	719,47			44	5,33	<0,005	16	Descomposición Estacional	1	188,6	67,3	19833,6	$Y_t = 43,7 + 3,00 \times t$	
	80,51			44	6,72	<0,005	15	Descomposición Estacional	1	259,8	78,5	29790,5	$Y_t = 74,1 + 1,16 \times t$	
	132,9			44	6,61	<0,005	14	Descomposición Estacional	1	214,3	96,8	35150,9	$Y_t = 26,8 + 2,82 \times t$	
	515,8	14	-487,8	43	10,48	<0,005	1	Promedio Móvil	1	69,7	78,3	65547,4	-	
	472,8	24,5	-423,8	42	8,74	<0,005	2	Promedio Móvil	1	75,7	79,9	52316,3	-	
	453,8	21,33	-411,13	41	7,51	<0,005	3	Promedio Móvil	1	86,4	82,4	48685,1	-	
a sin Valores Atípicos o Disruptivos	264,99	86,09	-92,8	44	7,64	<0,005	-	Suavizamiento Exponencial Óptimo $\alpha=0,057$	1	162,9	73	37995,2	-	CAUSALES
	232,89	51,02	-130,86	44	7,43	<0,005	-	Suavizamiento Exponencial $\alpha=0,2$	1	137,5	74,2	38309,2	-	
	199,56	20,11	-159,34	44	8,77	<0,005	-	Suavizamiento Exponencial $\alpha=0,5$	1	81,7	73,2	43927,2	-	
	202,26	17,38	-167,5	44	9,77	<0,005	-	Suavizamiento Exponencial $\alpha=0,8$	1	70,1	75,5	54030,8	-	
a sin Valores Atípicos o Disruptivos	97,18			43	0,32	0,518	-	Tendencia Lineal	1	132,96	42,58	2757,74	$Y_t = 49,0 + 1,094 \times t$	CAUSALES
	59,6			43	1	0,011	-	Tendencia Exponencial	1	95,08	44,99	3263,76	$Y_t = 46,940 \times (1,0054^t)$	
	23,57			43	0,48	0,229	-	Tendencia Cuadrática	1	93,17	33,40	1810,08	$Y_t = -24,6 + 10,91 \times t - 0,2231 \times t^2$	



Producto	Pronóstico			N	AD	Valor p	Long. Estacional	Método Estadístico	Periodo	MAPE	MAD	MSD	Ecuación
a sin Valores Atípicos o Disruptivos	87,81			43	0,4	0,348	16	Descomposición Estacional	1	118,66	37,61	2069,95	$Y_t = 40,6 + 1,486 \times t$
	99,53			43	0,34	0,481	15	Descomposición Estacional	1	114,91	36,09	1893,04	$Y_t = 35,6 + 1,686 \times t$
	100,03			43	0,39	0,486	14	Descomposición Estacional	1	116,72	36,07	1955,78	$Y_t = 36,4 + 1,677 \times t$
	84,11	14	-56,11	42	0,62	0,099	1	Promedio Móvil	1	56,97	25,29	1279,48	-
	97,16	24,5	-48,16	41	0,67	0,075	2	Promedio Móvil	1	58,74	26,26	1374,18	-
	97,98	21,33	-55,32	40	0,53	0,162	3	Promedio Móvil	1	67,79	28,7	1529,38	-
	76,06	17,76	-40,56	43	0,8	0,035	-	Suavizamiento Exponencial Óptimo $\alpha=0,765963$	1	53,86	23,8	1190,42	-
	123,21	42,43	-38,35	43	0,52	0,176	-	Suavizamiento Exponencial $\alpha=0,2$	1	103,81	32,97	1992,79	-
	83,54	20,09	-43,36	43	0,72	0,057	-	Suavizamiento Exponencial $\alpha=0,5$	1	66,35	25,9	1307,21	-
	76,21	17,38	-41,45	43	0,73	0,054	-	Suavizamiento Exponencial $\alpha=0,8$	1	53,61	24,01	1194,21	-
b	659,56			44	10,41	<0,005	-	Tendencia Lineal	1	497	486	1789052	$Y_t = -22 + 15,1 \times t$
	N/A			Tendencia Exponencial			N/A						
	530,89			44	10,38	<0,005	-	Tendencia Cuadrática	1	539	504	1786164	$Y_t = -150 + 31,9 \times t - 0,37 \times t^2$
	264,26			44	5,27	<0,005	15	Descomposición Estacional	1	757	579	1345820	$Y_t = -103 + 18,3 \times t$
	229,67			44	6,27	<0,005	14	Descomposición Estacional	1	721	540	1380982	$Y_t = -16 + 15,8 \times t$
	315,57			44	7,83	<0,005	13	Descomposición Estacional	1	428	408	1077277	$Y_t = -7 + 15,7 \times t$
	3939,64	110	-3719,4	43	11,57	<0,005	1	Promedio Móvil	1	293	550	3817867	-
	3464,43	91	-3282,43	42	10	<0,005	2	Promedio Móvil	1	356	553	2962428	-

SERIES DE TIEMPO

CAUSALES



Producto	Pronóstico			N	AD	Valor P	Long. Estacional	Método Estadístico	Periodo	MAPE	MAD	MSD	Ecuación
b	3316,56	81,33	-3153,89	41	8,86	<0,005	3	Promedio Móvil	1	427	562	2724661	-
	1107,47	245,37	-616,72	44	14,04	<0,005	-	Suavizamiento Exponencial óptimo $\alpha=0,013$	1	213	352	1860431	-
	1496,33	314,62	-867,09	44	9,33	<0,005	-	suavizamiento Exponencial $\alpha=0,2$	1	369	482	2089292	-
	1363,1	97,9	-1167,31	44	9,75	<0,005	-	suavizamiento Exponencial $\alpha=0,5$	1	356	576	2511279	-
	1389,4	102,14	-1185,13	44	10,99	<0,005	-	suavizamiento Exponencial $\alpha=0,8$	1	303	525	3120616	-
b sin Valores Atípicos o Disruptivos	70,27			41	1,57	<0,005	-	Tendencia Lineal	1	52,5	30,33	1642,77	$Y_t = 73,3 - 0,072 \times t$
	57,15			41	1,67	<0,005	-	Tendencia Exponencial	1	43,6	28,83	1728,83	$Y_t = 68,683 \times (0,99563^t)$
	94,59			41	3,22	<0,005	-	Tendencia Cuadrática	1	46,42	28,42	1540,59	$Y_t = 97,6 - 3,47 \times t + 0,0808 \times t^2$
	196,1			41	2,28	<0,005	19	Descomposición Estacional	1	41	28,06	1905,52	$Y_t = 65,8 + 0,334 \times t$
	59,61			41	2,04	<0,005	18	Descomposición Estacional	1	35,9	25,57	1583,31	$Y_t = 73,0 - 0,127 \times t$
	34,36			41	2,34	<0,005	17	Descomposición Estacional	1	29,19	20,79	1113,24	$Y_t = 75,1 - 0,181 \times t$
	76,82			41	1,7	<0,005	16	Descomposición Estacional	1	47,65	30,38	2204,11	$Y_t = 74,2 - 0,139 \times t$
	119,71			41	0,48	0,225	15	Descomposición Estacional	1	43,11	26,68	1292,03	$Y_t = 74,7 - 0,123 \times t$
	50,63			41	0,66	0,078	14	Descomposición Estacional	1	37,66	23,38	1011,21	$Y_t = 77,3 - 0,279 \times t$
	90,33			41	1,24	<0,005	13	Descomposición Estacional	1	42,43	26,67	1612,99	$Y_t = 73,8 - 0,120 \times t$
	227,9	110	-7,9	40	0,96	0,014	1	Promedio Móvil	1	63,94	40,88	3618,43	-
	196,6	91	-14,6	39	0,86	0,025	2	Promedio Móvil	1	61,76	38,04	2902,67	-
	180,91	81,33	-18,24	38	1,37	<0,005	3	Promedio Móvil	1	59,62	36,77	2581	-

SERIES DE TIEMPO

CAUSALES



Producto	Pronóstico			N	AD	Valor P	Long Estacional	Método Estadístico	Periodo	MAPE	MAD	MSD	Ecuación
b sin Valores Atípicos o Disruptivos	N/A			Suavizamiento Exponencial Óptimo				N/A					
	156,59	80,52	4,45	41	2,55	<0,005	-	Suavizamiento Exponencial $\alpha=0,2$	1	51	31,05	1893,51	-
	172,92	90,42	7,92	41	1,38	<0,005	-	Suavizamiento Exponencial $\alpha=0,5$	1	53,65	53,67	2366,08	-
d	143,96	102,14	10,33	41	0,905	0,019	-	Suavizamiento Exponencial $\alpha=0,8$	1	58,85	37,48	2977,03	-
	95,38			44	11,27	<0,005	-	Tendencia Lineal	1	71,6	76,9	48184,8	$Y_t = 139,2 - 0,97 \times t$
	64,77			44	11,33	<0,005	-	Tendencia Exponencial	1	38,9	62,7	49432,7	$Y_t = 103,410 \times (0,98966^t)$
	24,16			44	8,76	<0,005	-	Tendencia Cuadrática	1	85,3	85,7	47229,8	$Y_t = 68 + 8,3 \times t - 0,206 \times t^2$
	48,14			44	8,37	<0,005	15	Descomposición Estacional	1	97,6	81,2	38143	$Y_t = 140,1 - 1,06 \times t$
	79,26			44	9,94	<0,005	14	Descomposición Estacional	1	64,2	72,1	41917,1	$Y_t = 143,2 - 1,13 \times t$
	62,41			44	9,74	<0,005	13	Descomposición Estacional	1	69,8	77,5	44341,5	$Y_t = 141,3 - 0,97 \times t$
	742,19	109	-524,19	43	9,41	<0,005	1	Promedio Móvil	1	109	107	104370	-
	630,94	95,5	-439,94	42	8,07	<0,005	2	Promedio Móvil	1	86,2	100,9	74632,5	-
	600,68	79,33	-442,02	41	7,47	<0,005	3	Promedio Móvil	1	94,2	102,2	70755,8	-
	271,28	102,2	-66,86	44	10,82	<0,005	-	Suavizamiento Exponencial Óptimo $\alpha=0,010$	1	56,6	69	49146,6	-
	296,3	82,01	-132,29	44	8,61	<0,005	-	Suavizamiento Exponencial $\alpha=0,2$	1	85,8	87,5	55191,3	-
	319,58	91,9	-135,78	44	8,53	<0,005	-	Suavizamiento Exponencial $\alpha=0,5$	1	88,7	92,9	66258,1	-

SERIES DE TIEMPO

CAUSALES

SERIES DE TIEMPO





Producto	Pronóstico			N	AD	Valor P	Long. Estacional	Método Estadístico	Periodo	MAPE	MAD	MSD	Ecuación
d	335,88	102,63	-130,62	44	9,65	<0,005	-	Suavizamiento Exponencial $\alpha=0,8$	1	94,4	95,2	83629,8	-
	64,26			43	2,6	<0,005	-	Tendencia Lineal	1	39,18	31,01	1639,56	$Y_t = 104,5 - 0,914 \times t$
	60,49			43	2,71	<0,005	-	Tendencia Exponencial	1	33,8	29,26	1685,42	$Y_t = 96,619 \times (0,98941^t)$
	81,64			43	3,12	<0,005	-	Tendencia Cuadrática	1	36,33	29,31	1587,03	$Y_t = 121,9 - 3,23 \times t + 0,0527 \times t^2$
	61,05			43	0,35	0,469	15	Descomposición Estacional	1	31,98	26,28	1225,71	$Y_t = 109,8 - 1,173 \times t$
	33,75			43	0,43	0,299	14	Descomposición Estacional	1	32,88	26,63	1289,72	$Y_t = 109,3 - 1,134 \times t$
	44,26			43	1,12	0,006	13	Descomposición Estacional	1	35,48	27,42	1542,92	$Y_t = 106,3 - 1,014 \times t$
	55,02			43	1,61	<0,005	12	Descomposición Estacional	1	31,62	25,99	1431,01	$Y_t = 106,5 - 0,968 \times t$
	226,67	109	-8,67	42	1,56	<0,005	1	Promedio Móvil	1	49,71	39,1	3604,43	-
	201,75	95,5	-10,75	41	0,58	0,126	2	Promedio Móvil	1	51,05	39,48	2938,49	-
d sin Valores Atípicos o Disruptivos	178,48	79,33	-19,81	40	0,81	0,034	3	Promedio Móvil	1	50,36	39,15	2558,86	-
	N/A			N/A				Suavizamiento Exponencial Óptimo	N/A				
	163,38	79,85	-3,69	43	1,88	<0,005	-	Suavizamiento Exponencial $\alpha=0,2$	1	44,25	34,1	1931,44	-
	179	91,9	4,8	43	1,08	0,007	-	Suavizamiento Exponencial $\alpha=0,5$	1	45,05	35,55	2380,71	-
	192,5	102,63	12,77	43	1,27	<0,005	-	Suavizamiento Exponencial $\alpha=0,8$	1	46,56	36,68	2982,83	-
	13,25			44	1,16	<0,005	-	Tendencia Lineal	1	57,81	7,97	91,49	$Y_t = 27,57 - 0,318 \times t$
k	11,09			44	1,32	<0,005	-	Tendencia Exponencial	1	46,78	7,45	95,25	$Y_t = 27,598 \times (0,97995^t)$

CAUSALES

SERIES DE TIEMPO



Producto	Pronóstico			N	AD	Valor De P	Long. Estacional	Método Estadístico	Periodo	MAPE	MAD	MSD	Ecuación
	18,37			44	1,34	<0,005	-	Tendencia Cuadrática	1	55,16	7,61	86,90	$Y_t = 32,70 - 0,987 \times t + 0,0149 \times t^2$
k	11,6			44	0,44	0,272	16	Descomposición Estacional	1	43,54	6,69	72,62	$Y_t = 28,43 - 0,357 \times t$
	21,65			44	0,41	0,329	15	Descomposición Estacional	1	44,3	6,99	81,59	$Y_t = 29,04 - 0,374 \times t$
	5,7			44	0,22	0,836	14	Descomposición Estacional	1	48,43	6,5	66,9	$Y_t = 28,38 - 0,3594 \times t$
	35,52	10	-15,52	43	0,45	0,258	1	Promedio Móvil	1	61,35	10,21	169,47	-
	36,55	13,5	-9,55	42	0,31	0,533	2	Promedio Móvil	1	63,41	9,12	138,35	-
	40,33	17	-6,33	41	0,79	0,038	3	Promedio Móvil	1	75,59	9,73	141,71	-
	38,23	16,97	-4,29	44	1,28	<0,005	-	Suavizamiento Exponencial Óptimo $\alpha=0,057$	1	65,4	8,68	102,32	-
	37,66	16,62	-4,42	44	1,28	<0,005	-	Suavizamiento Exponencial $\alpha=0,2$	1	63,35	8,59	103,22	-
	36,41	14,36	-7,68	44	0,86	0,024	-	Suavizamiento Exponencial $\alpha=0,5$	1	61,32	9	119	-
	34,81	11,6	-11,62	44	0,49	0,209	-	Suavizamiento Exponencial $\alpha=0,8$	1	59,83	9,48	142,41	-

CAUSALES

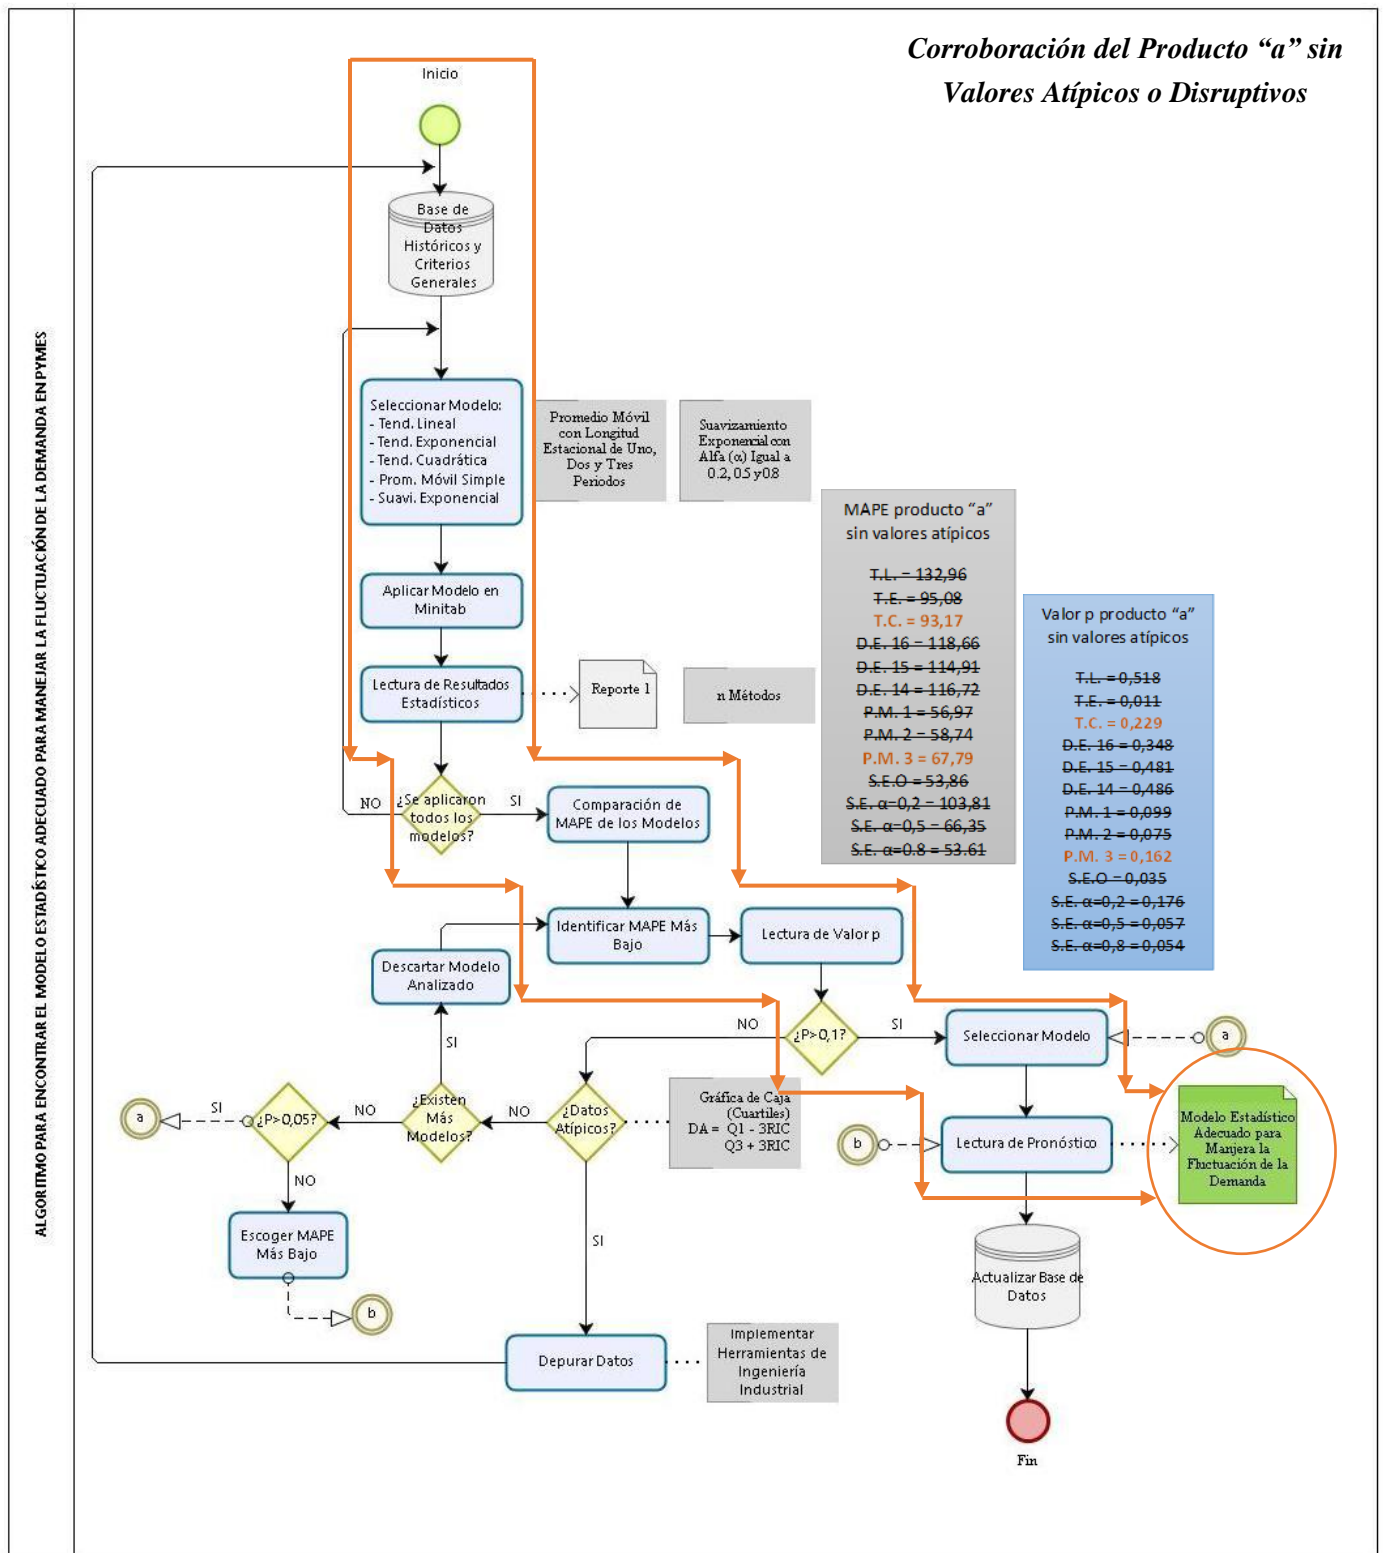
SERIES DE TIEMPO

## Anexo 2

Tabla de Resultados de las Gráficas de Caja

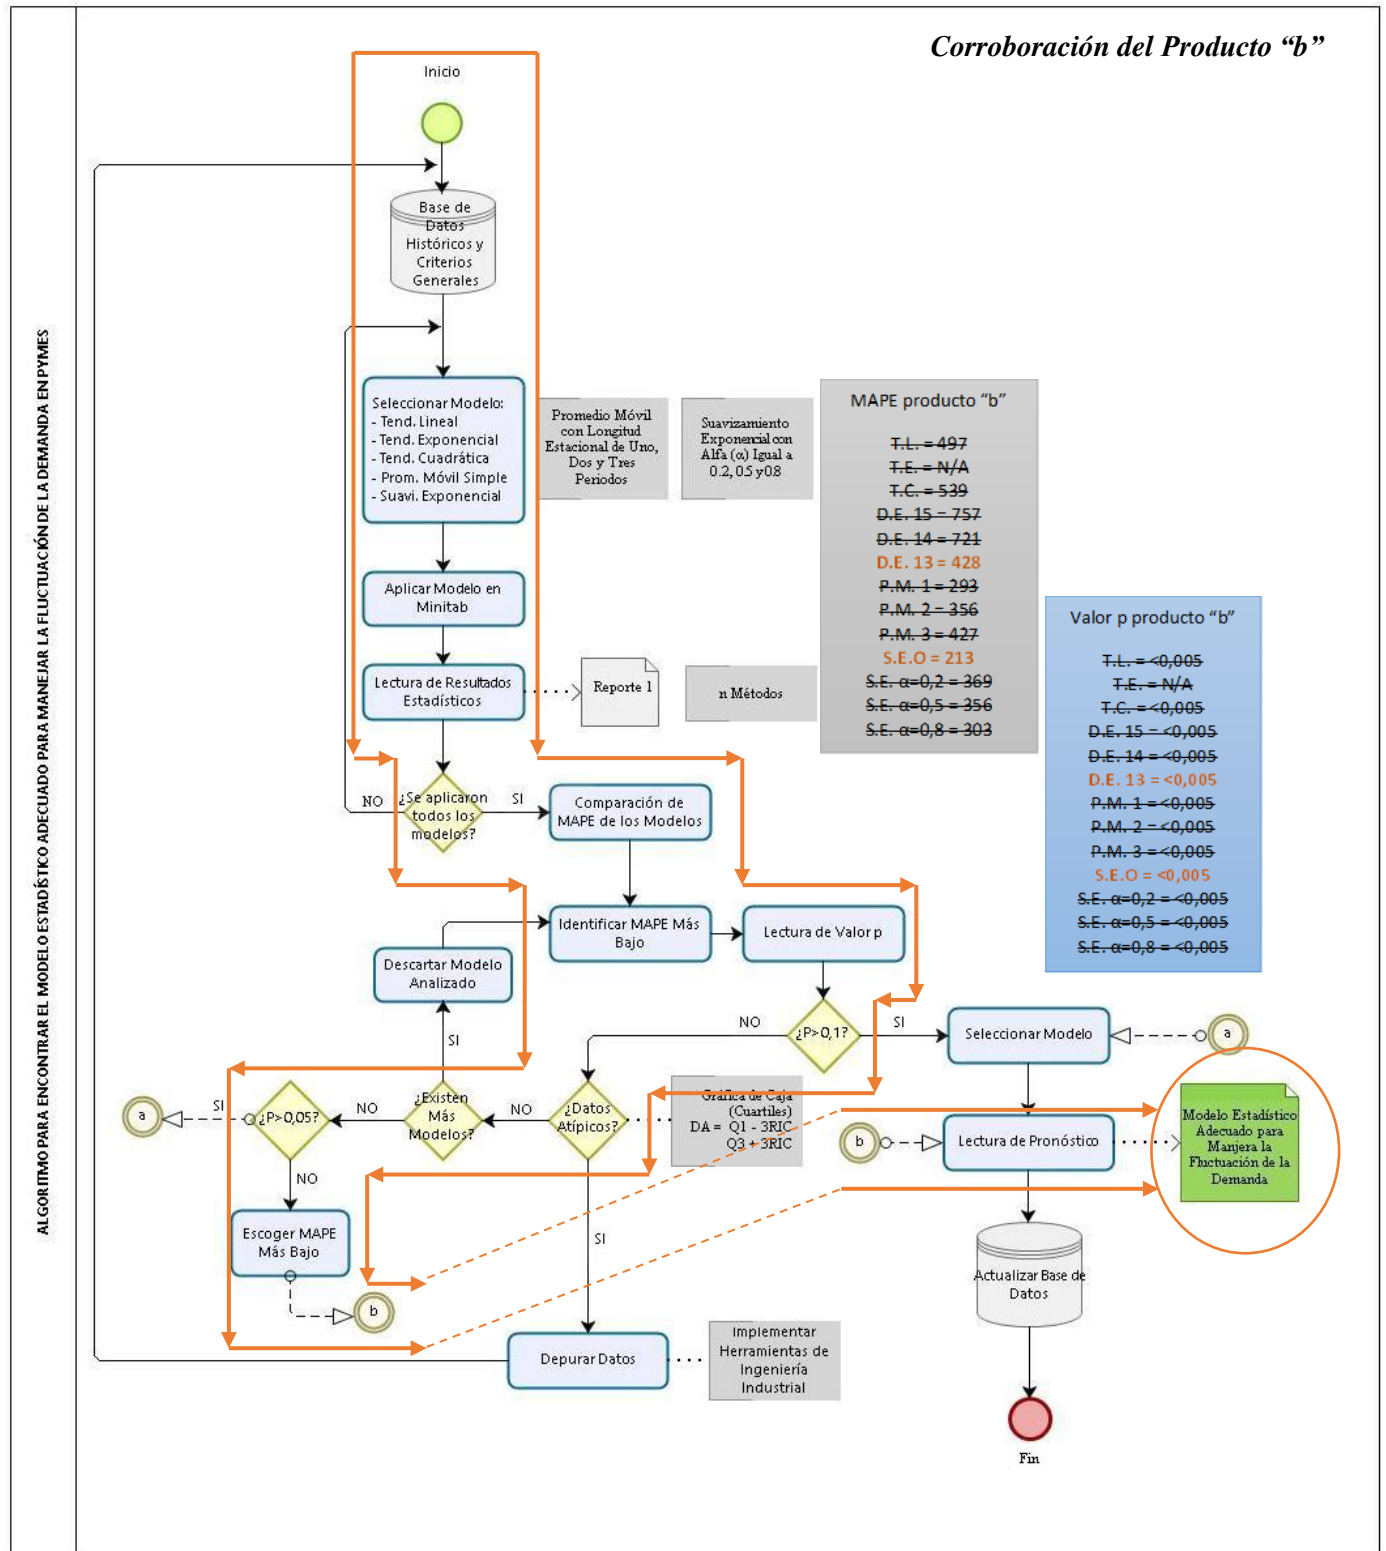
	Productos						
	a	a sin Datos Atípicos o Disruptores	b	b sin Datos Atípicos o Disruptores	d	d sin Datos Atípicos o Disruptores	k
Q1	25	25	43,75	44,5	54	54	11,25
Q2 (Mediana)	61	55	61,5	61	76	75	18
Q3	117,75	117	101	89,5	107,75	107	26,5
Rango Intercuartil	92,75	92	57,25	45	53,75	53	15,25
Bigotes	12; 238	12; 238	22; 169	22; 134	41; 155	41; 155	3; 39
N	44	43	44	41	44	43	44
Datos Atípicos	1314	-	8920,28 2229 -55,54	-	1533	-	-

## Anexo 3



Esta figura representa la corroboración del modelamiento planteado para el producto “a” sin valores atípicos o disruptivos. Obedeciendo los parámetros establecidos se obtuvo como el método más adecuado a la tendencia cuadrática dentro de los modelos causales, y al promedio móvil con longitud estacional de dos periodos dentro de los modelos de series de tiempo. Para el producto “a” sin valores atípicos o disruptivos ambos métodos siguieron el camino para resultar como los más adecuados.

## Anexo 4

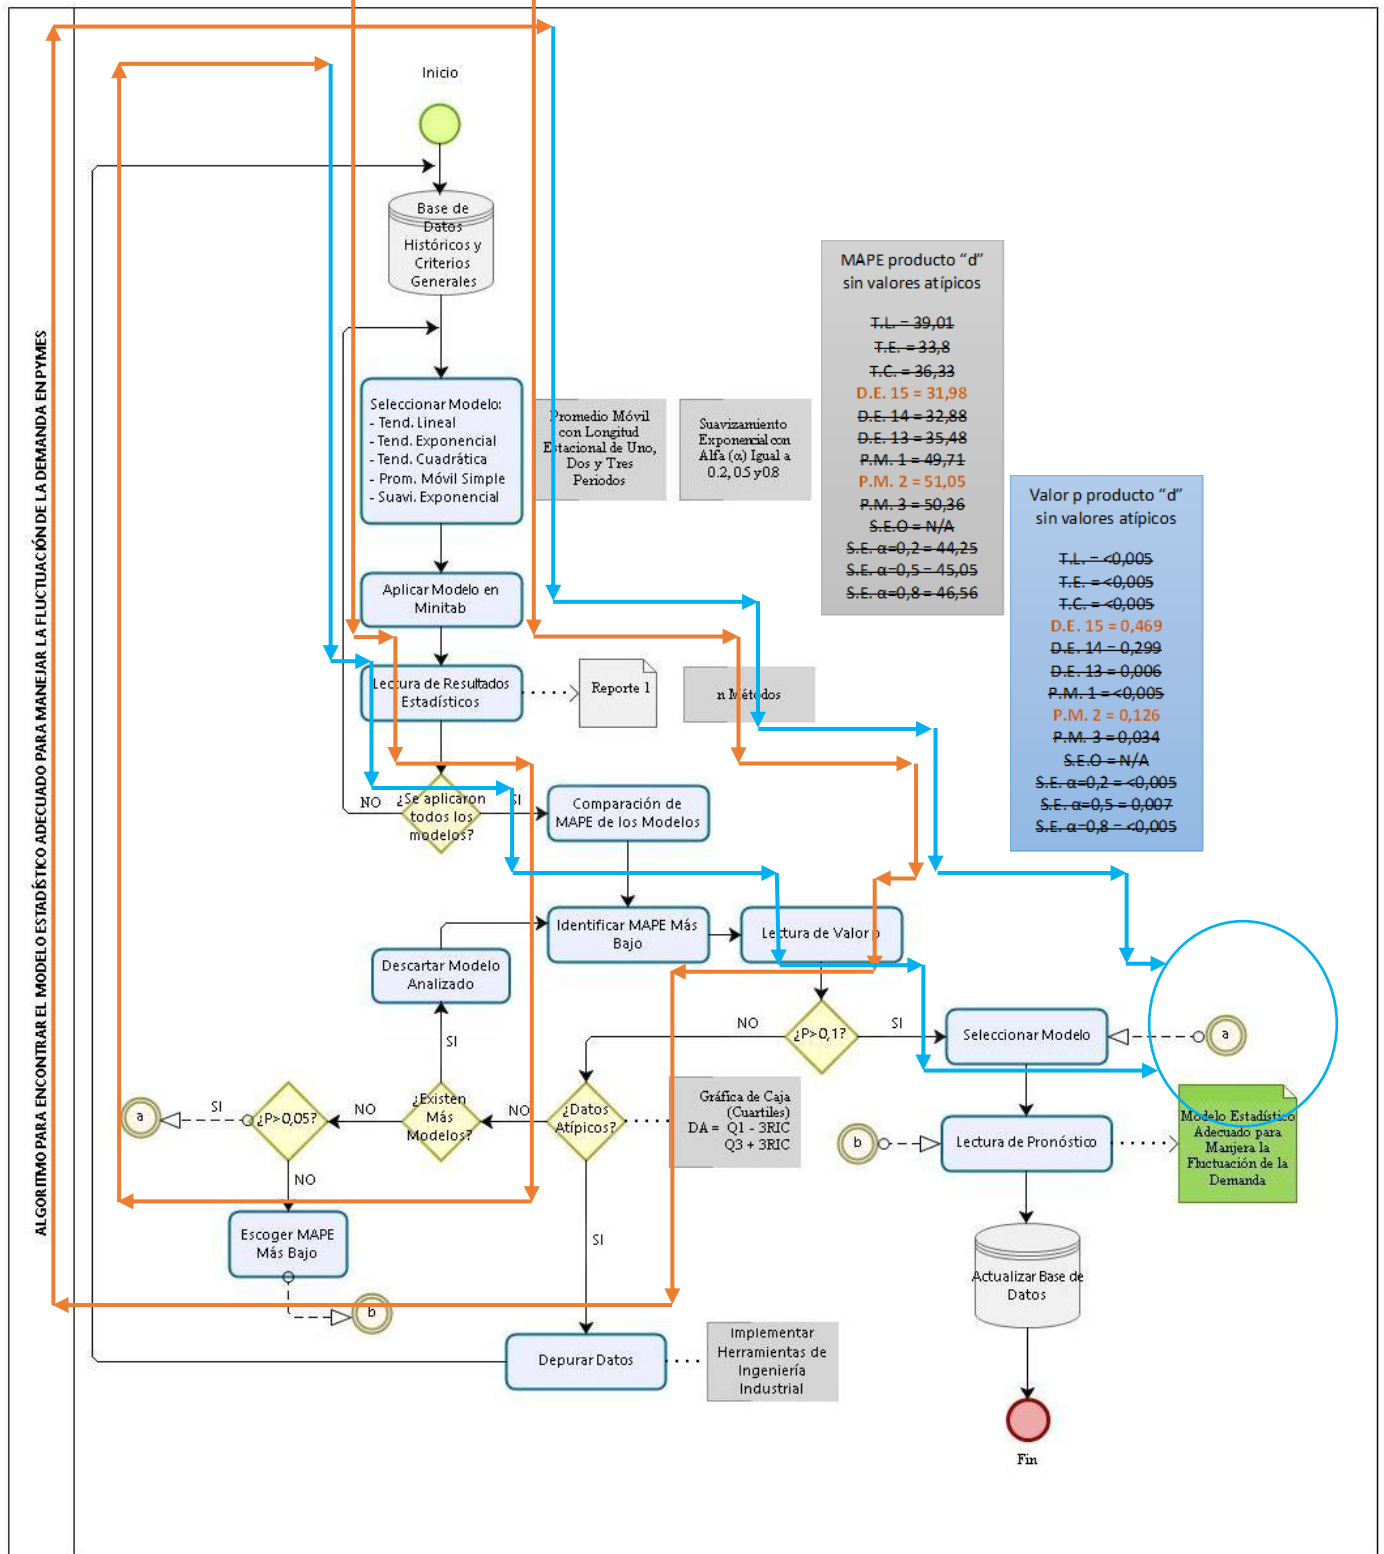


Esta figura representa la corroboración del modelamiento planteado para el producto “b”. Obedeciendo los parámetros establecidos se obtuvo como el método más adecuado a la descomposición estacional con longitud estacional de 13 periodos dentro de los modelos causales, y al suavizamiento exponencial óptimo con  $\alpha=0,013$  dentro de los modelos de series de tiempo. Para el

## Anexo 5

producto “b” con valores atípicos o disruptivos ambos métodos siguieron el camino para resultar como los más adecuados.

### Corroboración del Producto “d” sin Valores Atípicos o Disruptivos



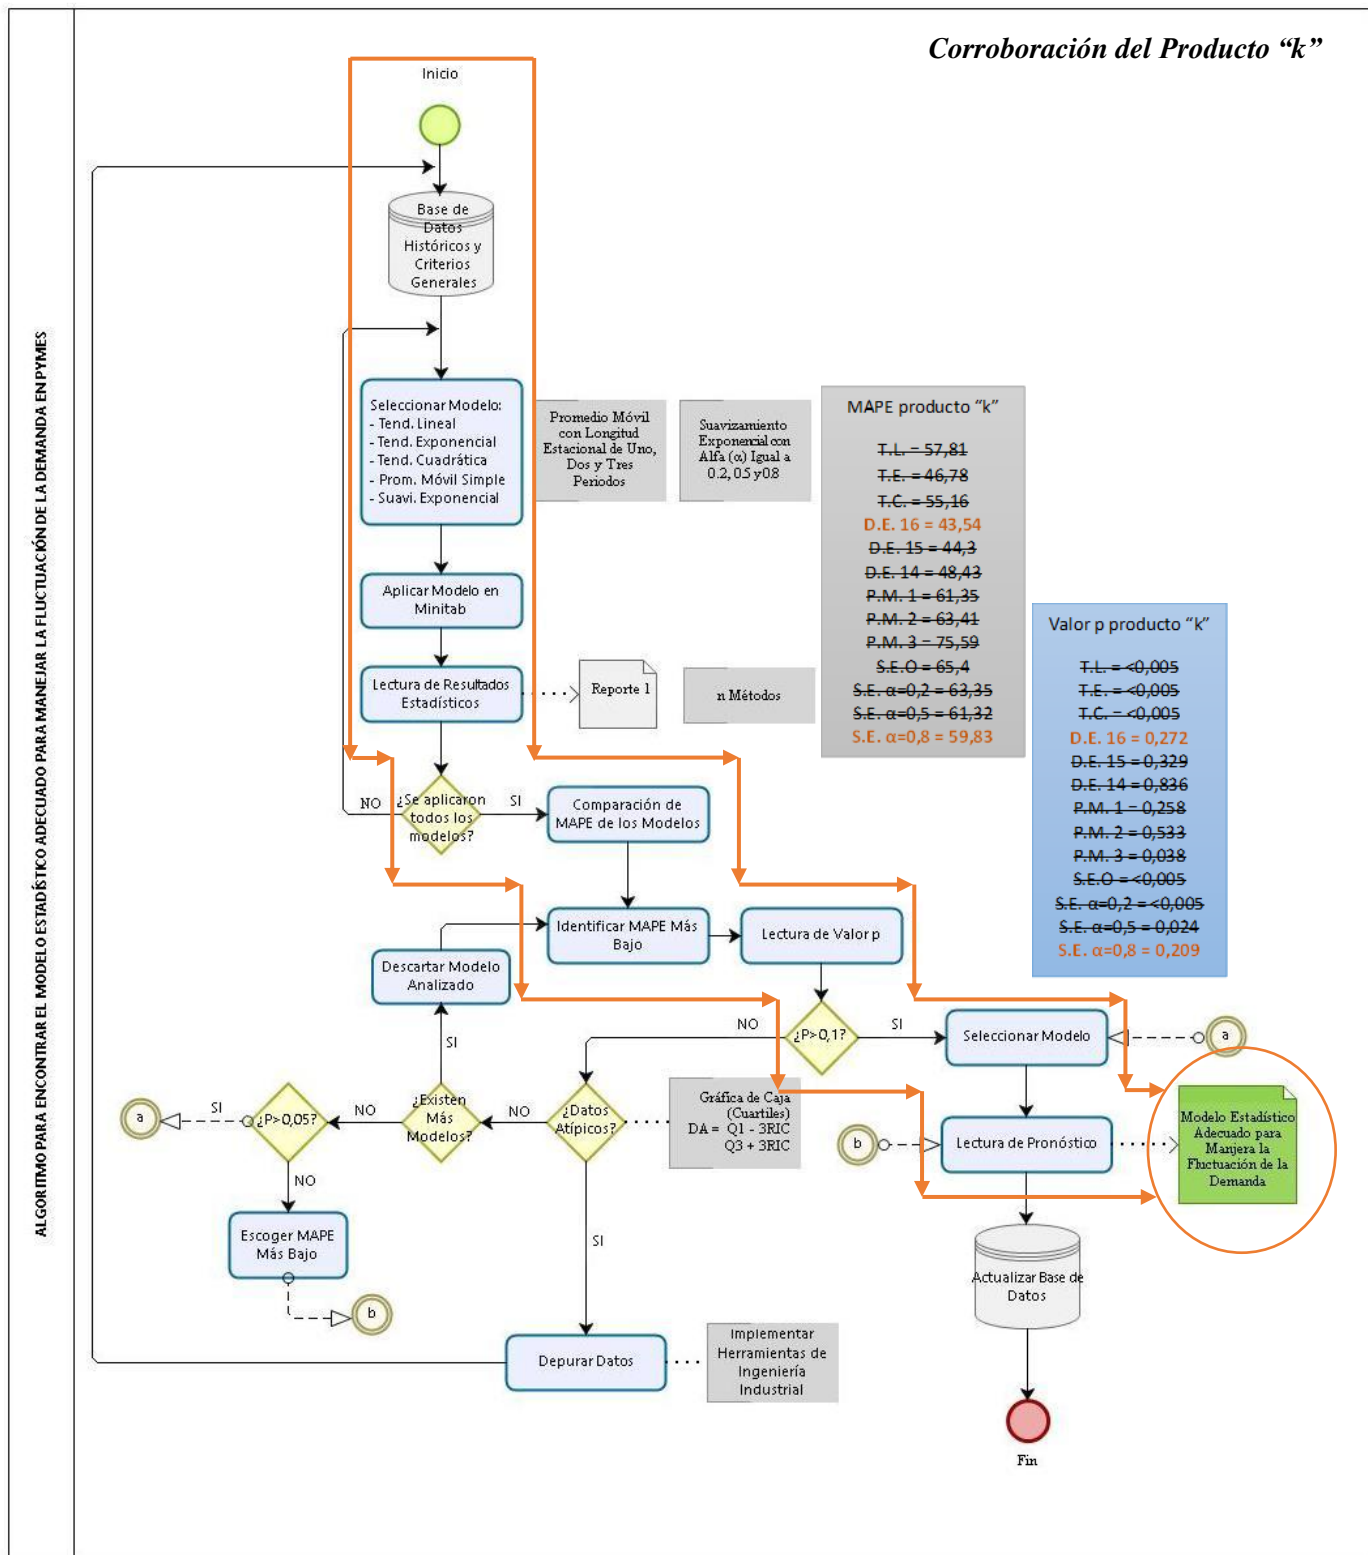
Esta figura representa la corroboración del modelamiento planteado para el producto “d” con valores atípicos o disruptivos. Obedeciendo los parámetros establecidos se obtuvo como el método más



adecuado a la descomposición estacional con longitud estacional de 15 periodos dentro de los modelos causales, y al promedio móvil con brinco de dos periodos dentro de los modelos de series de tiempo. Para el producto “d” ambos métodos siguieron el camino para resultar como los más adecuados.

## Anexo 6

### Corroboración del Producto "k"



Esta figura representa la corroboración del modelamiento planteado para el producto "k" que no presentaba valores atípicos o disruptivos. Obedeciendo los parámetros establecidos se obtuvo como el método más adecuado a la descomposición estacional con longitud estacional de 16 periodos dentro de los modelos causales, y al suavizamiento exponencial con  $\alpha=0,08$  dentro de los modelos de






series de tiempo. Para el producto “k” ambos métodos siguieron el camino para resultar como los más adecuados.



## Anexo 7

PRODUCTOS "A", "B", "D" Y "K" CON DATOS ANORMALES

— a — b ..... d — k





## Anexo 8

TODOS LOS PRODUCTOS

a b d k

